



**Simão Pedro Mendes Serrano**

Licenciatura em Ciências da Engenharia Eletrotécnica e de Computadores

## **Implementação de um sistema de previsão de produção fotovoltaica e consumos de um Edifício Inovador**

Dissertação para obtenção do Grau de Mestre em Engenharia Eletrotécnica e de Computadores

Orientador: João Murta Pina, Professor Auxiliar, FCT-UNL  
Co-orientador: Jorge Facão, Investigador, LNEG

Júri:

Presidente: Doutor Pedro Alexandre da Costa Sousa - FCT/UNL  
Arguente(s): Doutor Pedro Miguel Ribeiro Pereira - FCT/UNL  
Vogal(ais): Doutor João Miguel Murta Pina - FCT/UNL



## **Implementação de um sistema de previsão de produção fotovoltaica e consumos de um Edifício Inovador**

Copyright © Simão Pedro Mendes Serrano, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.



## **Agradecimentos**

Gostaria de começar por agradecer ao meu orientador, o Professor João Murta Pina, pela oportunidade de trabalhar este tema e pela ajuda fornecida.

Agradeço também ao meu co-orientador, o Doutor Jorge Facão, por me ter possibilitado a utilização de dados reais para o desenvolvimento do trabalho.

Gostaria também de agradecer à minha família, em particular aos meus pais, por todo o apoio, ajuda e carinho durante esta jornada. Agradeço também aos meus colegas e amigos pela amizade e apoio prestado



---

Nos dias de hoje, existe a consciencialização de que a energia fotovoltaica é aquela que apresenta uma maior sustentabilidade energética dos edifícios.

O objetivo desta dissertação foi prever a energia fotovoltaica produzida num edifício inovador, tendo por base os dados da temperatura ambiente e da irradiância, de modo a comparar os valores previstos com os valores reais.

Para a realização dos sistemas de previsão usamos o software Matlab R2019b e um modelo de redes neuronais do tipo NARX. Foi realizado um pré-processamento dos dados fornecidos com ajustamento do intervalo entre cada amostra (15 minutos) com divisão dos dados em 2 partes (treino e validação). No treino usamos os dados entre 2015 e 2017 e na validação os do ano de 2018. Quanto ao intervalo de medição a considerar para as 2 amostras foi entre as 5h e as 21h, e as redes foram testadas com 5, 8, 10, 12 e 15 neurónios na camada oculta e com conjuntos de treino de 15, 20, 25 e 30 dias de dados.

Após definirmos o conjunto de treino e o número de neurónios a aplicar nos preditores da temperatura e da irradiância (variáveis de entrada), estimamos a produção fotovoltaica (variável de saída).

As principais conclusões relativamente à produção fotovoltaica demonstraram que, os meses que apresentam valores mais elevados de produção (real e prevista) e com maiores diferenças ao nível da produção total, foram os meses do início do ano, onde os dias são mais curtos. Os que apresentaram valores mais baixos, embora com uma tendência de subida, foram os meses entre a primavera e o outono (dias maiores). Foi também durante estes meses que observamos uma menor diferença na produção fotovoltaica, entre a produção real e prevista, o que demonstra que nesta fase houve um melhor comportamento dos dados usados, e por sinal uma melhor performance que pode ser explicada pela presença de mais dias de sol e dias mais longos.

**Palavras-chave:** Produção fotovoltaica; Temperatura; Irradiância; Redes neuronais

---





## Abstract

---

Nowadays, there is an awareness that photovoltaic energy is the one among renewable energies that presents the greatest energy sustainability in buildings.

The main goal of this dissertation was to predict the photovoltaic energy produced by an nZEB (near zero energy building), based on temperature and irradiance data, in order to compare the predicted values with the actual values.

In the development of the forecasting systems we used the MATLAB R2019b software and a NARX neural network model. The data pre-processing consisted in the adjustment of the interval samples (from 10 to 15 minutes) and in the division of the data between training and validation. In the training part, the data used was comprehended between 2015 and 2017, and in validation we used the data of 2018. The forecasting hours considered were between 5am and 9pm, where the networks were tested with 5, 8, 10, 12 and 15 neurons on the hidden layer and with datasets of 15, 20, 25 and 30 days.

After the selection of the training dataset and the number of neurons to be applied in the predictors of temperature and irradiance (input variables), we estimated the photovoltaic production (output variable).

The main conclusions regarding photovoltaic production showed that the months with the highest production values (actual and forecasted) and with the greatest differences in terms of the total production, were the months of the beginning of the year, where the days are shorter. The ones with the lowest values, although with an upward trend, were the months between spring and autumn (larger days). It was also during these months that we observed a smaller difference in terms of photovoltaic production, between the actual and estimated production, which demonstrates that in this phase there was a better behavior of the data used, and a better performance that can be explained by the presence of more sunny and longer days.

**Keywords:** Photovoltaic production; Temperature, Irradiance; Neural networks



## Conteúdo

1.	Introdução.....	1
1.1	MOTIVAÇÃO .....	2
1.2	OBJETIVO.....	2
1.3	ESTRUTURA DO TRABALHO .....	3
2.	REVISÃO DA LITERATURA .....	4
2.1	O CONCEITO DE ENERGIA FOTOVOLTAICA .....	4
2.1.1	SISTEMAS FOTOVOLTAICOS NO MUNDO, NA EUROPA E EM PORTUGAL.....	5
2.2	PRODUÇÃO E PREVISÃO FOTOVOLTAICA.....	7
2.2.1	<i>Métodos de Previsão</i> .....	9
2.2.1.1	Total Sky Imagery.....	9
2.2.1.2	Vetores de movimento de nuvens com base em satélites .....	10
2.2.1.3	Métodos baseados em técnicas de aprendizagem estocásticas .....	10
2.2.1.4	Métodos de previsão meteorológicos numérico.....	11
2.2.1.5	<i>Precisão da Previsão Efetuada</i> .....	12
2.3	REDES NEURONAIS.....	13
2.3.1	<i>Tipos de Redes Neurais</i> .....	14
2.3.1.1	MLP (rede neuronal perceptrão multicamada).....	14
2.3.1.2	RBFNN (Radial Basis Function neural network) .....	14
2.3.1.3	Redes Neurais Recorrentes .....	15
2.3.2	<i>Treino da Rede Neuronal</i> .....	17
2.4	EDIFÍCIOS NZEB'S.....	18
2.5	ESTADO DA ARTE: .....	18
3.	METODOLOGIA.....	22
3.1	TRATAMENTO E RECOLHA DE DADOS .....	22
3.1.1	<i>Escolha do atraso da rede</i> .....	24
3.1.2	<i>Ferramenta utilizada</i> .....	25
3.2	PREDITORES.....	27
3.2.1	<i>Temperatura</i> .....	28
3.2.2	<i>Irradiância</i> .....	29
3.2.3	<i>Produção Fotovoltaica</i> .....	31
4.	APRESENTAÇÃO DOS MODELOS EM ESTUDO .....	33
4.1	APRESENTAÇÃO MENSAL .....	33
4.1.1	<i>Janeiro</i> .....	33
4.1.2	<i>Fevereiro</i> .....	38
4.1.3	<i>Março</i> .....	43
4.1.4	<i>Abril</i> .....	48
4.1.5	<i>Maio</i> .....	53
4.1.6	<i>Junho</i> .....	58
4.1.7	<i>Julho</i> .....	63
4.1.8	<i>Agosto</i> .....	67
4.1.9	<i>Setembro</i> .....	72
4.1.10	<i>Outubro</i> .....	77
4.1.11	<i>Novembro</i> .....	82
4.1.12	<i>Dezembro</i> .....	87
4.2	APRESENTAÇÃO ANUAL .....	92
	BIBLIOGRAFIA.....	97

## Índice de Gráficos

Gráfico 1 - EQM obtido para cada atraso no preditor da temperatura.....	24
Gráfico 2 - EQM obtido para cada atraso no preditor da irradiância .....	25
Gráfico 3 - EQM do preditor de temperatura para Abril.....	29
Gráfico 4 - EQM do preditor de irradiância para Abril.....	30
Gráfico 5 - EQM do preditor da produção fotovoltaica em Abril.....	32
Gráfico 6 - EQM do preditor de temperatura para Janeiro .....	34
Gráfico 7 - EQM do preditor de irradiância para Janeiro.....	35
Gráfico 8 - Produção fotovoltaica por hora real e prevista para Janeiro.....	37
Gráfico 9 - EQM do preditor de temperatura para Fevereiro .....	38
Gráfico 10 - EQM do preditor de irradiância para Fevereiro.....	40
Gráfico 11 - Produção fotovoltaica por hora real e prevista para Fevereiro.....	42
Gráfico 12 - EQM do preditor de temperatura para Março .....	43
Gráfico 13 - EQM do preditor de irradiância para Março .....	45
Gráfico 14 - Produção fotovoltaica por hora real e prevista para Março .....	47
Gráfico 15 - EQM do preditor de temperatura para Abril .....	48
Gráfico 16 - EQM do preditor de irradiância para Abril .....	50
Gráfico 17 - Produção fotovoltaica por hora real e prevista para Abril .....	52
Gráfico 18 - EQM do preditor de temperatura para Maio.....	53
Gráfico 19 - EQM do preditor de irradiância para Maio.....	55
Gráfico 20 - Produção fotovoltaica por hora real e prevista para Maio.....	57
Gráfico 21 - EQM do preditor de temperatura para Junho .....	58
Gráfico 22 - EQM do preditor de irradiância para Junho.....	60
Gráfico 23 - Produção fotovoltaica por hora real e prevista para Junho.....	62
Gráfico 24 - EQM do preditor de temperatura para Julho.....	63
Gráfico 25 - EQM do preditor de irradiância para Julho.....	64
Gráfico 26 - Produção fotovoltaica por hora real e prevista para Julho.....	66
Gráfico 27 - EQM do preditor de temperatura para Agosto .....	67
Gráfico 28 - EQM do preditor de irradiância para Agosto.....	69
Gráfico 29 - Produção fotovoltaica por hora real e prevista para Agosto.....	71
Gráfico 30 - EQM do preditor de temperatura para Setembro .....	72
Gráfico 31 - EQM do preditor de irradiância para Setembro .....	74
Gráfico 32 - Produção fotovoltaica por hora real e prevista para Setembro .....	75
Gráfico 33 - EQM do preditor de temperatura para Outubro .....	77
Gráfico 34 - EQM do preditor de irradiância para Outubro .....	79
Gráfico 35 - Produção fotovoltaica por hora real e prevista para Outubro .....	81
Gráfico 36 - EQM do preditor de temperatura para Novembro .....	82
Gráfico 37 - EQM do preditor de irradiância para Novembro .....	84
Gráfico 38 - Produção fotovoltaica por hora real e prevista para Novembro .....	86
Gráfico 39 - EQM do preditor de temperatura para Dezembro .....	87
Gráfico 40 - EQM do preditor de irradiância para Dezembro .....	89
Gráfico 41 - Produção fotovoltaica por hora real e prevista para Dezembro .....	91
Gráfico 42 - comparação entre a produção fotovoltaica total real e prevista anual .....	93

## Índice de Figuras

Figura 1 - Evolução da capacidade solar fotovoltaica instalada no planeta.....	5
Figura 2 - Evolução da capacidade solar fotovoltaica instalada no continente Europeu .....	6
Figura 3 - Evolução da capacidade solar fotovoltaica instalada em Portugal .....	6
Figura 4 - Fluxograma do comportamento de um modelo físico.....	8
Figura 5 - Passos do método de previsão Total Sky Imagery.....	9
Figura 6 - Vetores de movimento no método vetores de movimento de nuvens com base em satélites.....	10
Figura 7 - Rede Neuronal com as diferentes camadas (retirado de Valkov, 2017) .....	13
Figura 8 - Topologia de uma rede neuronal recorrente.....	15
Figura 9 - Topologia em <i>OpenLoop</i> .....	16
Figura 10 - Topologia em <i>Closed Loop</i> .....	16
Figura 11 - Fachada sul do edifício Solar XXI .....	23
Figura 12 - Interface gráfica de apoio à criação dos modelos de previsão .....	26
Figura 13 - Topologia em <i>Open Loop</i> .....	27
Figura 14 - Topologia em <i>Closed Loop</i> .....	27

## Índice de Tabelas

Tabela 1 - Média do EQM do preditor da temperatura para Janeiro.....	35
Tabela 2 - Média do EQM do preditor da irradiância para Janeiro .....	36
Tabela 3 - Média do EQM do preditor da temperatura para Fevereiro .....	39
Tabela 4 - Média do EQM do preditor da irradiância para Fevereiro .....	41
Tabela 5 - Média do EQM do preditor da temperatura para Março.....	44
Tabela 6 - Média do EQM do preditor da irradiância para Março .....	46
Tabela 7 - Média do EQM do preditor da temperatura para Abril.....	49
Tabela 8 - Média do EQM do preditor da irradiância para Abril .....	51
Tabela 9 - Média do EQM do preditor da temperatura para Maio .....	54
Tabela 10 - Média do EQM do preditor da irradiância para Maio .....	56
Tabela 11 - Média do EQM do preditor da temperatura para Junho.....	59
Tabela 12 - Média do EQM do preditor da irradiância para Junho .....	61
Tabela 13 - Média do EQM do preditor da temperatura para Julho .....	64
Tabela 14 - Média do EQM do preditor da irradiância para Julho .....	65
Tabela 15 - Média do EQM do preditor da temperatura para Agosto .....	68
Tabela 16 - Média do EQM do preditor da irradiância para Agosto .....	70
Tabela 17 - Média do EQM do preditor da temperatura para Setembro .....	73
Tabela 18 - Média do EQM do preditor da irradiância para Setembro .....	74
Tabela 19 - Média do EQM do preditor da temperatura para Outubro .....	78
Tabela 20 - Média do EQM do preditor da irradiância para Outubro .....	80
Tabela 21 - Média do EQM do preditor da temperatura para Novembro .....	83
Tabela 22 - Média do EQM do preditor da irradiância para Novembro .....	85
Tabela 23 - Média do EQM do preditor da temperatura para Dezembro .....	88
Tabela 24 - Média do EQM do preditor da irradiância para Dezembro .....	90
Tabela 25 - Combinação anual do conjunto de treino e número de neurónios para os preditores da temperatura e irradiância .....	92



# 1. Introdução

O panorama mundial debate-se nos dias de hoje com vários problemas interligados, e que representam uma ameaça irreversível tanto para o planeta como para as sociedades contemporâneas. Um dos maiores desafios, é a necessidade de garantir o fornecimento de energia à escala global, de forma a poder dar resposta às necessidades energéticas dos países desenvolvidos ou em vias de desenvolvimento, e que são motivados pelo acelerado crescimento da população mundial e sua concentração nas cidades. Carlisle, Elling & Penney (2008) referem a este respeito, que entre 2001 e 2025 as previsões de aumento das necessidades energéticas à escala global situam-se na ordem dos 54%, motivadas pelo consumo dos setores industriais, construção civil (ramo habitacional) e dos transportes.

Outro desafio, prende-se com o controlo do aquecimento global resultante das emissões de CO<sub>2</sub> para a atmosfera causada pela poluição e consequente efeito de estufa, de forma a garantir padrões ambientais fundamentais para a vida no planeta. Finalmente o desafio de redução dos combustíveis fósseis por serem provenientes de fontes de natureza finita, e por terem preços cada vez mais elevados, que associados aos problemas ambientais podem ser um problema para as sociedades futuras.

Para atingir os desafios colocados pela utilização excessiva de recurso fósseis na produção da energia, os governantes de diferentes países estabeleceram em 1997 um protocolo internacional, (Protocolo de Quioto) onde foram definidas metas para a redução dos níveis de CO<sub>2</sub> na atmosfera, e assim mitigar os problemas causados. Mais recentemente a conferência de Paris em 2015, onde Portugal esteve presente, vem reforçar a necessidade do cumprimento dos acordos que foram sendo estabelecidos ao longo do tempo, uma vez que era notória a presença de alterações climáticas que representam uma ameaça irreversível quer para o planeta, quer para a sociedade.

Alguns autores (Mancilha, 2013; Monteiro, 2014; Calhau, 2015 e Costa 2016) salientam que a solução pode ser encontrada nas energias renováveis consideradas limpas, por preservarem o meio ambiente e fazer parte de um futuro mais sustentável.

Em Portugal tem ocorrido nos últimos anos um investimento enorme em centrais de energias renováveis, tanto no solar fotovoltaico, como em parques eólicos. A importância que os governantes têm sobre esta matéria, levaram à necessidade de adoção deste novo paradigma energético, aproveitando as condições climáticas e geográficas que o país possui.

## 1.1 Motivação

Nos últimos anos a capacidade instalada de energia fotovoltaica tem tido um crescimento exponencial em todo o mundo. Maia (2018) tomando por base os dados da REN21 (2017) refere que a energia fotovoltaica foi de entre as energias renováveis a que apresentou um maior crescimento e onde houve mais investimentos a nível global. O autor acrescenta que atualmente estima-se que estejam mais de 400 GW instalados no mundo inteiro (IRENA, 2018).

Quanto a projeções futuras, Chaturvedi & Isha (2016), referem que a procura mundial de energia está projetada para ser o dobro da procura atual para o ano de 2050, e para ser o triplo da atual no término do presente século. Esta projeção é reveladora do potencial de crescimento deste setor e por isso, é determinante para garantir a sustentabilidade no futuro, prevenir o aumento de mudanças climáticas e do aquecimento global, olhar para as tecnologias renováveis como uma garantia de preservação do nosso planeta (Anwar & Deshmukh, 2018), uma vez que recursos suficientes de energias limpas estão diretamente conectados com a estabilidade global, a prosperidade da economia e qualidade de vida. Encontrar fontes de energia que satisfaçam a procura mundial será um dos maiores desafios da sociedade para o presente século (Chaturvedi & Isha, 2016).

Assim, a escolha deste tema teve por base a sua atualidade, potencial e importância a nível académico, económico, social e ambiental, bem como o interesse pessoal no desenvolvimento e aprofundamento de conhecimentos sobre uma tecnologia inovadora tão importante para Portugal e para o mundo em que vivemos.

## 1.2 Objetivo

Esta dissertação tem como temática o desenvolvimento de modelos de previsão fotovoltaica. O principal objetivo do estudo foi prever a energia fotovoltaica produzida num edifício inovador (nZEB), mais especificamente o LNEG (Laboratório Nacional de Energia e Geologia) situado em Lisboa, tendo por base os dados referentes à temperatura ambiente e à radiação proveniente do sol (irradiância), de modo a comparar os valores previstos com os valores reais para avaliar a performance dos modelos desenvolvidos. Para treino dos mesmos serão usados os dados dos anos compreendidos entre 2015 e 2017, enquanto que os de 2018 serão usados para cálculo da previsão desejada, que abrangerá um período temporal de 16 horas (desde as 5h até às 21h). Utilizaremos uma tecnologia de previsão baseada em redes neuronais recorrendo ao *software MATLAB*, sendo deste modo possível realizar computacionalmente a previsão esperada, criando uma relação entre os dados de entrada e os dados de saída da rede (Gebben, Bader & Oelmann, 2015) permitindo modelar todo o sistema como uma só entidade.



Após a modelação das diversas redes neuronais (uma por cada mês do ano), serão guardados os pesos resultantes das previsões efetuadas, de modo a ser possível construir um modelo que efetue a previsão em tempo real.

### 1.3 Estrutura do trabalho

A dissertação que apresentamos está estruturada em 6 partes:

Na primeira parte começamos com uma introdução onde apresentamos a motivação e o objetivo desta dissertação.

Na segunda parte e para situar a temática da nossa investigação, faremos uma revisão da literatura onde esclarecemos o conceito, produção e previsão de energia fotovoltaica, falamos sobre a importância das redes neuronais, a sua classificação e tipos, abordamos ainda a importância dos edifícios NZEB tão relevantes para atingir as metas climáticas e energéticas a nível europeu. No final desta parte apresentaremos o estado da arte fazendo referência aos resultados de alguns estudos desenvolvidos nos últimos anos sobre a temática.

Na terceira parte apresentaremos a metodologia e arquitetura do sistema proposto, onde começamos por descrever o processo de tratamento de dados, a ferramenta computacional a utilizar para o treino dos modelos e os procedimentos a adotar na obtenção dos preditores iniciais, que servirão como base à construção dos preditores para os restantes meses.

Na quarta parte serão apresentados os resultados obtidos relativamente aos estudos efetuados. Em cada mês, evidenciaremos os valores do erro quadrático médio obtido quer no preditor da temperatura quer no da irradiância, de modo a escolher a melhor combinação entre o conjunto de treino e o número de neurónios presentes na camada oculta a utilizar, apresentaremos também a comparação entre a produção fotovoltaica real e a estimada pelos modelos desenvolvidos. No final serão evidenciados os valores referentes ao ano de 2018 relativamente ao número de neurónios presentes na camada oculta a utilizar, bem como o conjunto de treino que apresentará melhores resultados para o erro quadrático médio.

Após esta fase, serão apresentadas as principais conclusões e algumas considerações a ter em conta em trabalhos futuros a desenvolver relacionados com esta temática.

Finalmente na sexta parte transcrevemos a bibliografia consultada, que serviu de base para algumas das decisões tomadas durante a realização da dissertação.

## 2. Revisão da Literatura

### 2.1 O conceito de energia fotovoltaica

A partir da radiação proveniente do sol é possível produzir energia através do efeito fotovoltaico. Este é definido pela Comissão Internacional de Eletrotécnica como um “efeito fotoelétrico em que é produzida uma diferença de potencial entre dois pontos pela absorção de fótons”, tendo sido descoberto por Alexandre Edmond Becquerel, em 1839. Segundo Costa (2016), trata-se de um processo quântico de excitação de elétrons, sendo criados pares elétron-lacuna utilizados na condução de corrente elétrica aquando da existência de um campo elétrico.

A energia solar fotovoltaica é segundo Pinho & Galdino (2014) um tipo de energia muito usada nos nossos dias em situações muito diversificadas (alimentação de vários aparelhos e abastecimento de casas produção de energia elétrica a grande escala através de redes de distribuição). É um tipo de energia obtida através da conversão direta da luz em energia elétrica sendo a célula fotovoltaica a unidade fundamental desse processo de conversão. A energia solar fotovoltaica consiste assim, na transformação de radiação proveniente diretamente do sol em energia elétrica, utilizando para esse efeito células fotovoltaicas, sendo estas agrupadas para formar os módulos fotovoltaicos.

Serra (2010) refere que a energia oriunda do sol e que atinge a superfície terrestre apresenta um valor médio de  $1700 \text{ kWh/m}^2$ , sendo que o seu total anual excede o consumo energético mundial em dez mil vezes, observando-se a grande disponibilidade de energia solar que poderá ser aproveitada no nosso planeta. David (2014) refere que este tipo de energia é visto como uma excelente opção de utilização para um futuro recente ao invés do uso de recursos fósseis, contribuindo para a redução das emissões de gases causadores de efeito de estufa, e consequentemente do aquecimento global.

Serra (2010), para além de mencionar que esta forma de produção de energia renovável tem vindo a sofrer um crescente aumento de interesse por parte da economia mundial, constata também que a colocação e incorporação de tecnologia com capacidade para produção de energia

fotovoltaica em edifícios assumiu uma grande importância uma vez que permite baixar os custos da energia consumida.

### 2.1.1 Sistemas Fotovoltaicos no Mundo, na Europa e em Portugal

Segundo a IRENA (International Renewable Energy Agency), a energia solar é utilizada globalmente quer seja para gerar energia elétrica ou para aquecer água.

A capacidade instalada a nível global de produção de energia elétrica através de radiação proveniente do sol tem aumentando de forma exponencial, como é possível observar na figura seguinte:




Figura 1 - Evolução da capacidade solar fotovoltaica instalada no planeta

Esta organização não governamental refere que no final do ano de 2015 estavam instalados cerca de 227 GW, como se pode observar na figura 1, o que consistia aproximadamente em 1% da energia elétrica utilizada a nível mundial. Durante a última década, as maiores contribuições para o crescimento observado ocorreram da parte de países como a Alemanha, China, Estados Unidos da América, entre outros.

Na Europa também ocorreu um aumento ao longo dos anos relativamente à capacidade instalada, e no final do ano de 2015 havia cerca de 100 GW instalados no continente, representando cerca de 44% da capacidade mundial. O maior aumento percentual ocorreu de 2010 para 2011, sendo que os três anos que se seguiram apresentaram um declínio na percentagem instalada, como demonstrado na figura:




Figura 2 - Evolução da capacidade solar fotovoltaica instalada no continente Europeu

Os países que mais contribuíram para que a Europa seja o continente com a maior percentagem na produção fotovoltaica foram a Alemanha (44 MW), a Itália (19 MW), o Reino Unido (9 MW), entre outros, segundo as estatísticas apresentadas pela IRENA.

Relativamente a Portugal, a IRENA estima que no final do ano de 2020, 31% da energia consumida seja obtida através de energias renováveis. Para além da energia hidroelétrica e eólica, também a energia solar tem recebido cada vez mais atenção, e a capacidade instalada tem vindo a aumentar de ano para ano:




Figura 3 - Evolução da capacidade solar fotovoltaica instalada em Portugal

Atualmente, no nosso país estão instalados cerca de 700 MW. Uma das maiores instalações do mundo é a central solar fotovoltaica da Amareleja, produzindo sensivelmente 93 GWh por ano.

## 2.2 Produção e previsão fotovoltaica

Devido à densidade de potência da energia solar ser a mais elevada, comparativamente a outras formas de recolha de energia como por exemplo a energia eólica (proveniente da potência do vento), a produção fotovoltaica é das soluções mais adotadas para produção de energias renováveis (Gebben, Bader & Oelmann, 2015).

Os sistemas fotovoltaicos transformam energia solar em energia elétrica, processo que apresenta alguma variabilidade, uma vez que a produção de energia depende da radiação solar proveniente do Sol, das características de cada painel fotovoltaico (Chaturvedi & Isha, 2016), das condições meteorológicas do local, e da temperatura ambiente, o que poderá acartar novos desafios para os operadores responsáveis por cada sistema.

Segundo Agoua et al, (2017), a integração na rede da energia gerada por sistemas fotovoltaicos tem sofrido um aumento nos últimos anos em diferentes países, graças à redução nos custos de produção desta tecnologia, e também devido à existência de políticas que favorecem o seu desenvolvimento. De modo a responder a tais desafios, e devido às razões técnico-económicas referidas anteriormente, é importante poder observar e antecipar os níveis de produção. Assim, tanto para parques eólicos como para parques fotovoltaicos, ocorreu um grande desenvolvimento a nível de modelos de previsão, de modo a ser possível prever a potência de saída obtida até um período de 24 horas, sendo que, para injeção em grande escala na rede da energia produzida, a previsão da produção é dada como um pré-requisito e é extremamente crucial, dado que poderão ocorrer falhas de estabilidade e segurança na rede (Zhou, et al, 2019).

As soluções existentes e publicadas nos últimos anos caracterizam-se em modelos físicos, estatísticos ou híbridos (Leva, Dolara, Grimaccia, Mussetta & Ogliari, 2018), de entre os quais se destacam as técnicas baseadas em “machine learning”, usando como base Redes Neurais Artificiais (ANN) (Zhou, Zhang, Yang & Liu, 2019), uma vez que a sua utilização poderá ajudar na procura de soluções que tornarão as aplicações de energia solar cada vez mais viáveis (Yaïci, Entchev, Longo, Brenna & Foiadelli, 2015).

Segundo Nespoli, Ogliari, Dolara, Grimaccia, Leva & Mussetta (2015), a utilização de redes neurais artificiais é a técnica que garante maior nível de precisão em termos de previsão fotovoltaica dentro dos modelos estatísticos.

Pelland et al, (2013), refere que os modelos de previsão podem ser descritos como físicos ou estatísticos. A abordagem utilizada pelos métodos físicos tem por base a utilização de módulos solares e fotovoltaicos de modo a ser possível gerar as respetivas previsões, enquanto que os modelos estatísticos se baseiam principalmente em dados fornecidos que são usados para o treino de modelos.

Os passos fundamentais do comportamento de um modelo físico encontram-se na figura seguinte, de onde é possível retirar que as variáveis que têm maior influência sobre a produção de energia fotovoltaica são a irradiância ao nível do plano do módulo, e a temperatura a que a célula fotovoltaica se encontra.

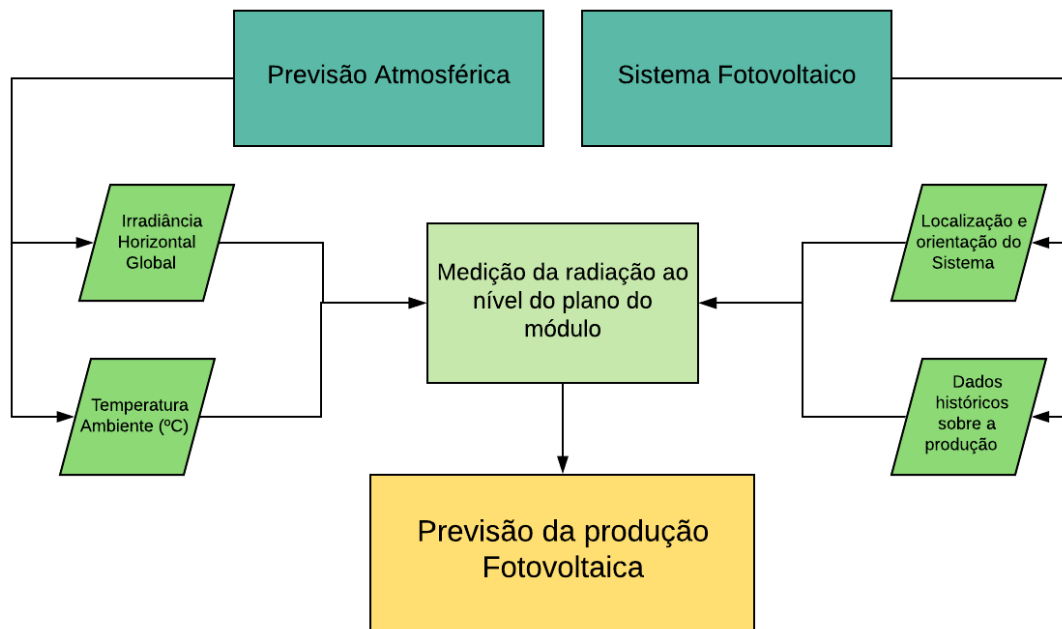


Figura 4 - Fluxograma do comportamento de um modelo físico

Por outro lado, as abordagens estatísticas usam um ou mais conjuntos de dados que contêm a produção fotovoltaica efetuada, assim como variáveis de entrada que poderão ou não ser usadas. Estes conjuntos são de seguida utilizados para treinar modelos de previsão. Assim, consegue-se antecipar uma estimativa da produção fotovoltaica num determinado instante temporal.

### 2.2.1 Métodos de Previsão

Os métodos de previsão são fundamentais para ajudar na previsão fotovoltaica, devido à necessidade de injetar na rede elétrica a energia coletada em módulos fotovoltaicos (Jones, 2011). Pelland et al. (2013), declara que consoante o intervalo temporal desejado para a previsão da produção fotovoltaica, existem vários métodos diferentes que podem ser considerados.

#### 2.2.1.1 Total Sky Imagery

O método “total sky imagery” tendo por base fotografias tiradas ao céu, acompanha o movimento das nuvens e utiliza técnicas de processamento de imagem para obter previsões em tempo real, podendo ser possível estender esse intervalo de tempo até 30 minutos.

Segundo Pelland et al. (2013), a previsão solar que se apoia integralmente sobre este método consiste em 4 passos fundamentais. Em primeiro lugar, é necessário obter uma imagem ou fotografia do estado inicial do céu nas imediações do local de previsão para posterior identificação das nuvens. Com um dispositivo capaz de fornecer imagens sucessivas da mesma zona, é possível estimar a sua deslocação e velocidade sendo estas variáveis armazenadas em vetores de movimento. Por fim, utilizando a localização das nuvens e os vetores de movimento, consegue-se prever a curto prazo a nebulosidade presente no céu, a irradiância solar e a produção fotovoltaica existente.




Figura 5 - Passos do método de previsão Total Sky Imagery

Embora esta tecnologia apresente como vantagem a divulgação de informação detalhada sobre a dimensão a estrutura e o movimento da nebulosidade no momento da previsão, fica aquém

das expectativas em relação à dissipação e variação da geometria nas nuvens, como refere Pelland et al. (2013).

#### 2.2.1.2 Vetores de movimento de nuvens com base em satélites

O segundo método apresenta bastantes semelhanças com o primeiro, pois também se detetam padrões descritos pelas nuvens, obtidos através de imagens tiradas com infravermelhos em sensores localizados nos vários satélites. O modelo de vetores de movimento de nuvens com base em satélites através da quantidade de luminosidade proveniente da Terra que atravessa as nuvens e atinge os diferentes satélites, calcula a transmissividade. Deste modo, é possível determinar a profundidade da nebulosidade e por imagens consecutivas saber os vetores de movimento.




Figura 6 - Vetores de movimento no método vetores de movimento de nuvens com base em satélites

A maior vantagem comparativamente ao método anterior, o “total sky imagery”, é o facto da área que um satélite abrange ser bastante maior, para além de englobar o mundo inteiro, a qualidade apresentada nas imagens fornecidas por satélites é claramente superior. As imagens de satélite são consideradas como sendo a melhor forma de previsão até um horizonte temporal de 5 horas (Perez et al. 2010).

#### 2.2.1.3 Métodos baseados em técnicas de aprendizagem estocásticas

Os métodos de aprendizagem estocásticos identificam padrões presentes em diferentes variáveis, sendo possível prever a radiação futura disponível, através do treino de algoritmos e utilizando dados históricos anteriormente armazenados.

Aplicando este método obtêm-se resultados com enorme precisão para previsões até 2 ou 3 horas. Pedro e Coimbra (2012) referem que o uso de melhores equipamentos de previsão, e de



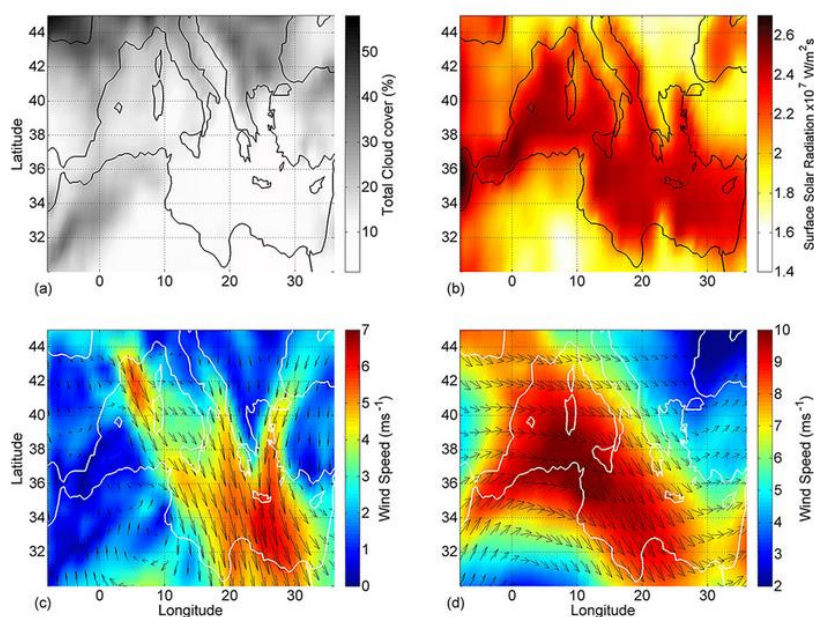
variáveis de input exógenas relevantes provenientes dos métodos anteriormente referidos melhora significativamente a exatidão das soluções obtidas.

Nos últimos anos, novos algoritmos de previsão que vão para além dos até então utilizados métodos de reconhecimento de padrões, têm ganho especial atenção. Estas novas técnicas têm por base um processo de otimização que usa propriedades da rede neuronal em questão, tais como os seus pesos iniciais e os seus coeficientes, de modo a evoluir a sua topologia. Assim parâmetros como os números de neurónios e de camadas ocultas, pesos iniciais, entre outros podem ser reajustados com a finalidade de atingir uma solução ótima.

#### 2.2.1.4 Métodos de previsão meteorológicos numérico

“Os modelos numéricos de previsão do tempo, tal como o nome indica, preveem parâmetros como a irradiância, a temperatura ambiente e a velocidade do vento sendo estas variáveis posteriormente inseridas num modelo físico para prever a geração de energia fotovoltaica” (Saint-Drenan, Good & Braun, pp. 257-276, 2017.)

O método de previsão apresentado baseia-se em equações dinâmicas que ao se basearem nas condições iniciais, conseguem prever a evolução dos fenómenos atmosféricos durante vários dias.



Existem modelos que englobam todos os outros métodos anteriores, denominados modelos globais, pois cobrem toda a superfície terrestre. Traunmüller e Steinmaurer, (2010), referem que devido à sua complexidade e computacionalidade existem apenas catorze a funcionar de momento no mundo inteiro.

Pelland et al. (2013), também refere que os melhores resultados de antevisão da produção solar para o dia seguinte, conseguem-se atingir através da combinação das previsões dos modelos numéricos de previsão do tempo com pós-processamento de dados dessas mesmas estimativas. Assim, é viável utilizar os resultados obtidos pelos modelos para melhorar a sua capacidade de

cálculo, e para realizar novas previsões que não são obtidas à saída dos modelos numéricos, como por exemplo da irradiância global horizontal ou da produção fotovoltaica.

#### 2.2.1.5 Precisão da Previsão Efetuada

Pelland et al, (2013), referem que têm sido utilizados diversos quantificadores de erro para avaliar a precisão das previsões solares e fotovoltaicas. A escolha de qual o mais apropriado pode variar consoante a aplicabilidade da tarefa a desenvolver. Geralmente as previsões apresentam erros, e certos quantificadores refletem o custo que esses erros apresentam ao influenciar determinados resultados. Para aferir o rigor das previsões efetuadas utilizam-se quantificadores de erros, porém é importante especificar qual o quantificador a utilizar, se o seu cálculo tem em conta apenas horas de exposição solar ou se é realizado tendo em conta um período de 24 horas.

Beyes et al. (2009) e Madsen et al. (2005) propõem diversos quantificadores de erros usados, sendo os mais comuns o erro quadrático e quadrático médio, medida do desvio das previsões em relação ao valor efetivo e sua raiz respetivamente, o erro médio absoluto, (desvio médio das previsões em relação aos valores efetivos), e o desvio padrão, ( $\sigma$ ). Madson (2005) refere que a dimensão dos erros é proporcional à sua influência nas previsões efetuadas e, assim sendo, o erro quadrático médio é o melhor quantificador a utilizar.

A precisão associada à previsão de energia ou à previsão de radiação solar é afetada por várias incertezas associadas aos diferentes passos que constituem o referido processo.

## 2.3 Redes neuronais

Segundo Anwar e Deshmukh (2018, p.64), uma rede neuronal é “um ramo da Inteligência Artificial (IA), que derivou da ideia do sistema nervoso humano”, e tal como o seu nome indica, resulta da inter-conectividade entre vários neurónios de diferentes camadas (Yadav, Malik & Chandel, 2015), funcionando como uma excelente ferramenta de investigação permitindo processamento de dados, reconhecimento de padrões e a resolução de equações não lineares por aproximação. Fente & Singh (2018), classificam as redes neuronais como uma ferramenta computacional poderosa, orientada a dados, e com capacidade de capturar características não-lineares apresentando um elevado nível de precisão nos resultados apresentados. Apontam-nas também como sendo um sistema que ao receber dados de entrada, se encontra apto para processar a informação neles contida, proporcionando dados de saída correspondentes. Heidari, et al. (2018), afirmam que as redes neuronais também podem ser referidas como modelos de aprendizagem que apresentam resultados fiáveis ao serem confrontadas com problemas onde as principais características não podem ser interpretadas individualmente. Miloudi & Acheli (2015), mencionam que no ramo da meteorologia, são usadas de modo a especular a radiação solar, com a finalidade de vir a ser possível considerar tal previsão em todos os locais do globo. Assim sendo, têm sido objeto de intenso estudo e as principais aplicabilidades vão desde tarefas de reconhecimento e agrupamento até classificação e previsão de valores.

Uma rede neuronal apresenta vários parâmetros tais como: variáveis de entrada, pesos associados a essas mesmas variáveis, junções ou nós e variáveis de saída, e é composta por três tipos diferentes de camadas, como poderemos observar na figura 7.




Figura 7 - Rede Neuronal com as diferentes camadas (retirado de Valkov, 2017)

A camada de entrada, a camada de saída e uma camada situada entre as duas anteriores, denominada camada oculta, onde os neurónios recebem parâmetros com um determinado peso, sendo estes ajustados de modo a produzir a saída desejada, minimizando o erro obtido (Yadav, Malik, 2014). Os pesos poderão ser positivos ou negativos, e quanto maior for o seu valor, maior a

influência dessa variável (Yadav, Malik, 2014). O tamanho da rede também pode variar, pois quanto mais complexo for o sistema maior será a dimensão da rede. (Fente & Singh, 2018).

De modo a desenvolver um modelo, a rede passa por três fases distintas. Primeiramente ocorre a fase de treino ou aprendizagem, seguida da parte de validação e finalizada com a fase de teste. Apresentando, portanto, capacidade de aprender, guardar e relembrar informação, baseando-se num conjunto de dados de treino (Anwar e Deshmukh, 2018).

### 2.3.1 Tipos de Redes Neurais

Na literatura podemos encontrar diferentes tipos de redes neurais consoante a finalidade do estudo, cada uma com as suas particularidades, sendo as mais citadas as seguintes:

#### 2.3.1.1 MLP (rede neuronal perceptrão multicamada)

As redes neurais do tipo “feedforward” são as mais populares a utilizar quando o objetivo é compreender e aproximar modelos computacionais, devido à sua estrutura avançada de camadas em paralelo (Ojha et al, 2017).

Uma subclasse deste tipo de redes é a rede perceptrão que apresenta apenas uma camada sendo, portanto, chamada de “single-layer perceptron” e é considerada a forma mais simples que existe na área das redes neurais, pois contém apenas duas camadas, uma de entrada e outra de saída (Yi-Chung, 2014). Porém, como estes modelos não conseguiam lidar de forma eficiente com os problemas da não linearidade, as redes perceptrão multicamada foram propostas. Devido a apresentarem uma ou mais camadas ocultas não estão suscetíveis ao mesmo problema que as anteriores. (Chen et al, 2015). São as mais utilizadas para resolver problemas de aproximação, classificação e previsão de resultados.

As redes neurais artificiais deste tipo apresentam três camadas distintas de neurónios e os seus pesos são obtidos pelo algoritmo de *backpropagation*, que consiste na propagação de erros em sentido contrário (Park, Venayagamoorthy & Harley, 2005).

#### 2.3.1.2 RBFNN (Radial Basis Function neural network)

Assim como as MLP, também as RBF são um tipo de rede em que a informação presente nos sinais avança apenas da camada de entrada para a camada de saída, percorrendo as diferentes camadas escondidas entre estas, sendo realizadas transformações não lineares durante o trajeto. (Zeng & Qiao, 2011). Em modo de comparação relativamente às MLP, neste tipo de rede, os sinais inicialmente não apresentam pesos associados a si (Park, Venayagamoorthy & Harley, 2005). Segundo Yadav e Malik (2014), as RBF alcançam uma solução ótima por ajuste dos pesos usando métodos de otimização linear.

### 2.3.1.3 Redes Neurais Recorrentes

As redes neurais recorrentes, tal como o nome indica, implicam recorrência, ou seja, utilizam informação recolhida num estado anterior e que foi difundida para o estado atual de modo a completarem a tarefa em questão. Segundo Vilela & Mateus, (2016), este tipo de redes são as que se encontram mais apropriadas e mais bem-sucedidas no que toca à resolução de problemas onde o objetivo é a previsão de dados já que a sua realimentação de dados influencia fortemente tanto a sua capacidade de aprendizagem como o seu desempenho. Na figura seguinte observamos um exemplo de uma topologia interna de uma rede neuronal recorrente.




Figura 8 - Topologia de uma rede neuronal recorrente

Embora estes dois tipos de redes sejam os mais utilizados, as redes neurais recorrentes utilizam a sua memória interna de modo a processar sequências arbitrárias de dados de entrada, segundo Nazaripouya et al, (2016) e Sarwat (2018), indica que as redes neurais não lineares autorregressivas (NARX), têm vindo a evoluir no sentido de melhor avaliar a influência entre as entidades de entrada e os parâmetros de saída.

Tendo em conta este tipo de redes neurais recorrentes, Hamdam (2013), declara que os modelos NARX são preferíveis utilizar quando a previsão incide sobre a radiação solar, e El Hendouzi, (2016), refere que são uma ferramenta muito poderosa no tratamento e na previsão de problemas mais complexos, como por exemplo a previsão da produção fotovoltaica. O autor apresenta estes modelos como modelos dinâmicos recorrentes, que contêm realimentação de dados envolvendo várias camadas da rede. Ao realizar uma previsão, o próximo valor previsto da serie temporal, é estimado utilizando valores anteriores dos dados de entrada (independentes) e valores anteriores dos dados de saída da rede.

Os modelos produzidos baseados em arquiteturas de redes neurais não lineares autorregressivas (NARX), possuem dois tipos distintos de arquiteturas. El Hendouzi, et al. (2016), explicita o contraste entre ambas, afirmando que a configuração em série, *Open Loop*, é utilizada na parte de treino da rede, onde são calculados os pesos e avaliada a rede, enquanto que a topologia em paralelo, (*Closed Loop*), apresenta como principal propósito a realimentação dos dados de saída, de forma a ser possível realizar a previsão em estudo.

Nas figuras seguintes é possível observar a distinção mencionada.



Figura 9 - Topologia em *OpenLoop*




Figura 10 - Topologia em *Closed Loop*

### 2.3.2 Treino da Rede Neuronal

Em projetos que trabalhem com redes neurais, um dos pontos fulcrais passa pelo treino da rede neuronal em si.

O treino de redes neurais consiste na aprendizagem da relação existente entre os parâmetros de entrada e as variáveis em estudo, analisando as bases de dados recolhidas para o treino (Yaici, Entchev, Longo, Brenna & Foiadelli, 2015), e uma vez que em cada iteração ocorre atualização dos diferentes pesos entre neurónios em diferentes camadas, relativos às variáveis de entrada, são comparados os resultados esperados com os obtidos na iteração anterior, resultando numa atualização conforme com os resultados (Ogliari, Dolara, Grimaccia, Leva & Mussetta, 2015).

Para os autores referidos anteriormente, uma das vantagens da utilização de redes neurais é a sua capacidade de trabalhar com extensas bases de dados, permitindo a utilização de inúmeros parâmetros, tornando possível obter um modelo com melhor performance entre diferentes sessões de treino consecutivas aumentando o número de neurónios utilizados (Gebben, Bader & Oelmann, 2015). O processo de treino termina quando os resultados obtidos se encontrarem englobados no intervalo de tolerância estabelecido para o estudo (Yaici, Entchev, Longo, Brenna & Foiadelli, 2015).

Assim sendo, primeiramente é necessário estabelecer as condições e variáveis de entrada e conhecer de que forma a rede varia e atualiza os valores dos pesos relativos às variáveis, tendo em conta o tipo de rede neuronal utilizada.

## 2.4 Edifícios NZEB'S

Segundo D'Agostino e Mazzarella (2018), um dos principais objetivos Europeus para que as metas climáticas e energéticas sejam cumpridas, passa pela redução da energia consumida em edifícios, uma vez que este setor é responsável por uma parte significativa do consumo global de Energia na União Europeia (Asdrubali, Evangelisti & Guattari, 2018). Os autores acrescentam que a Economia mundial tem prestado especial atenção à não utilização de combustíveis fósseis, e a “Energy Performance of Building Directive” (EPBD) refere que em território Europeu até 2021 todos os novos edifícios privados têm de ser “Net Zero Energy Building” (NZEB).

Um edifício NZEB apresenta um desempenho energético muito elevado, e a quantidade de energia que necessita deve ser coberta através de fontes renováveis produzidas no local ou nas proximidades. A comissão Europeia de Recomendação sobre Orientações para a promoção deste tipo de edifícios afirma que terá de existir flexibilidade energética, de modo a que o impacto das condições climáticas não influencie as necessidades energéticas dos NZEB's. (D'Agostino & Mazzarella, 2018).

Também nos Estados Unidos existe uma preocupação relativamente a esta temática. Os autores anteriores referem que o “Department of Energy” (DOE) considera que um edifício ZEB (zero energy building) deve ser “Um edifício com eficiência energética, onde a energia anual consumida apresenta um valor menor ou igual à energia renovável exportada”.

## 2.5 Estado da Arte:

Os aspetos relacionados com produção e previsão fotovoltaica estão presentes em variados setores (empresarial, comercial...), obtendo grande relevo tanto para a economia mundial como para o desenvolvimento de novas tecnologias que visam melhorar as condições habitacionais da população mundial. Iremos então apresentar alguns estudos realizados a nível global sobre a temática da “implementação de um sistema de previsão fotovoltaica utilizando redes neurais”.

Yadav e Malik (2014), desenvolveram um estudo onde procuraram comparar diferentes modelos de redes neurais para previsão da radiação proveniente do sol, utilizando diferentes combinações de variáveis meteorológicas. O objetivo principal foi comparar o desenvolvimento do modelo de redes neurais com uma ferramenta de ajuste (nftool) com uma rede neuronal RBFNN (radial basis function neural network) na previsão de radiação solar. Para tal, foram utilizadas três combinações de variáveis, medidas pelo departamento meteorológico da Índia em diferentes cidades. Os resultados obtidos demonstram que para a primeira e segunda combinações, uma “radial basis function neural network” (RBFNN) apresenta melhores resultados comparativamente à “neural fitting tool” (nftool), (“mean absolute percentage error” - MAPE de 4,94% e “absolute fraction of variance” –  $R^2$  de 96,18%). No caso da nftool os valores obtidos apresentam um MAPE mais elevado e um  $R^2$  mais reduzido. Concluindo-se então que uma técnica baseada em “radial basis



function neural network” (RBFNN) utilizando como parâmetros de entrada a latitude, longitude, altura acima do nível médio da água do mar e o número de horas de radiação solar pode ser utilizado para prever a radiação solar onde não existem estações de medição.

Larson, Nonnenmacher & Coimbra (2016), no seu estudo procuraram realizar uma previsão para o dia seguinte da produção de energia solar de módulos fotovoltaicos na Califórnia, em San Diego, Estados Unidos da América, uma região propícia para geração de energia utilizando a potência proveniente do sol. Os objetivos principais associados a este estudo passaram pela introdução e avaliação de um modelo de previsão da potência de saída de uma instalação fotovoltaica e pela investigação da variação anual da performance dos sistemas de previsão. Utilizaram-se dados provenientes de duas instalações (500kWp cada) tendo cada local providenciado resultados baseados em intervalos de quinze minutos, sendo reorganizados para apresentarem valores baseados em médias horárias, de modo a avaliar as previsões para o dia seguinte.

Analisando o erro absoluto médio (MAE), o erro quadrático médio (RMSE) entre outros, concluíram que é possível reduzir o erro da previsão de produção fotovoltaica para o dia seguinte, sendo deste modo possível realizar uma estratégia que visa a economização de energia elétrica proveniente da rede, numa zona tão benéfica para instalações solares como é o município de San Diego.

Para além de terem concluído que a performance anual dos sistemas de previsão depende de forma mais enfática dos dados usados na parte de performance, do que propriamente dos dados utilizados no conjunto de treino do modelo da rede, foi também constatado que a metodologia aplicada ao estudo não necessita de conhecimento prévio do modelo de previsão meteorológica utilizado para previsão da irradiância global horizontal (GHI).

Um estudo realizado no Laboratório de Tecnologia Solar no departamento de Energia do Politécnico de Milão por Nespoli et al. (2018), e que teve como principal objetivo a melhoria da previsão da potência fotovoltaica esperada, considerou diferentes abordagens de treino. O histórico de informação obtido relativamente à previsão meteorológica para o dia seguinte apresentava dois momentos distintos de recolha (11h e 23h), foram utilizados métodos de previsão para um intervalo de 12 horas e para um intervalo de 24 horas. Os autores consideraram dois conjuntos separados (conjunto de treino e o conjunto de validação) e usaram dados relativos a dois anos diferentes. Para o conjunto de treino foram utilizadas variáveis relativas ao ano de 2014, e para o conjunto de validação variáveis referentes ao ano de 2017. Para além da temperatura ambiente, da radiação global horizontal (GHI) e da radiação ao nível do plano do módulo fotovoltaico ( $G_{POA}$ ), que foram utilizados como parâmetros de entrada da rede neuronal, também consideraram a radiação calculada de acordo com o modelo de radiação a céu limpo (CSR), aumentando a capacidade de previsão providenciada pela rede.

Os resultados obtidos, apesar da tecnologia baseada em redes neurais conseguir suavizar as imprecisões ao nível da previsão da potência fotovoltaica esperada, demonstraram que quando existem variáveis que assumem valores completamente diferentes dos esperados, os resultados da previsão serão bastante afetados. Nas conclusões foram apresentadas as percentagens de amostras, tendo-se verificado que os valores da potência fotovoltaica prevista produzida superaram os valores da potência fotovoltaica medida, e também que as percentagens de amostras nas quais as radiações previstas por hora superaram os valores reais médios da radiação medida por hora. Daí podermos concluir que para o ano de 2017, das 3494 amostras totais, 40% apresentaram potência fotovoltaica prevista superior à medida, e que 75% apresentaram radiação prevista superior à radiação média medida. Também é referido que a previsão efetuada com maior exatidão ocorreu no dia dezassete de maio e a pior previsão ocorreu no dia onze de janeiro, como se pode observar nos gráficos 1 e 2:




Gráfico 1 - previsão e medição para o dia 17 de Maio




Gráfico 2 - previsão e medição para o dia 11 de Janeiro

As linhas azuis representam as previsões de potência produzida, enquanto que as linhas laranja representam as medições de potência produzida efetuadas para comparação de resultados.

Mohammed, Hamdan & Abdelhafez (2013) conduziram um estudo onde o principal objetivo seria a previsão da radiação solar horária em Amã, Jordânia. Com recurso ao software MATLAB, foi possível a construção e teste de um modelo NARX, testando vários algoritmos de treino e comparando a sua performance. Como variáveis de treino utilizaram dados compreendidos entre os anos de 2004 até 2007, enquanto que para teste da rede usaram os dados relativos a 2008, por não se encontrarem no conjunto de treino. Comparando os valores previstos com os valores reais, chegaram à conclusão que este tipo de modelo consegue com precisão reconhecer a relação existente entre as variáveis de entrada e saída da rede, de modo a ser possível efetuar a previsão

da radiação solar por hora, bem como que o melhor algoritmo de treino a empregar é o de *Marquardt-Levenberg*, visto apresentar o menor valor de erro quadrático médio e maior valor de regressão da rede, relativamente aos restantes algoritmos de treino testados.

Foi desenvolvido um estudo por Mohanty & Patra, (2015) na Índia, onde propuseram um modelo baseado em redes neuronais artificiais recorrentes, mais especificamente, um modelo NARX, que visou a estimação da radiação solar global diária utilizando parâmetros como a duração da luz proveniente do sol, a temperatura, a humidade, entre outras. O modelo em estudo foi desenvolvido e testado com recurso ao software MATLAB, aplicando como variáveis de treino da rede os dados compreendidos entre 2002 e 2005, e como variáveis de teste, os dados referentes a 2006. Após um pré-processamento, e após ocorrer a fase de treino, avaliando o valor mínimo do erro quadrático médio e o valor máximo da regressão da rede, concluíram que o algoritmo de *Marquardt-Levenberg* é o mais adequado para efetuar previsões solares.

## 3. Metodologia

Ao longo deste capítulo são apresentadas com maior detalhe as medidas e estratégias adotadas na elaboração do projeto, tendo como finalidade o desenvolvimento dos sistemas de previsão fotovoltaica.

Começamos por explicar a ferramenta utilizada, bem como o processo de tratamento de dados levado a cabo inicialmente. Em seguida, descrevemos os procedimentos utilizados na obtenção dos preditores necessários para o desenvolvimento de um sistema que faça a previsão em tempo real da quantidade de energia produzida por um módulo fotovoltaico.

### 3.1 Tratamento e recolha de Dados

O histórico de dados fornecidos pelo Laboratório Nacional de Energia e Geologia (LNEG), ou Solar XXI, edifício presente na imagem abaixo, serviram de base para a criação dos modelos de treino e previsão fotovoltaica. Tendo em conta o conceito do tema estudado e a natureza dos dados recolhidos, para a realização dos sistemas de previsão em causa adotamos a *toolbox nntool* existente no software *Matlab R2019b*, que é uma ferramenta que nos permitirá treinar a rede neuronal com uma interface relativamente simples e que serve de suporte ao processo de criação dos modelos a utilizar.



Figura 11 - Fachada sul do edifício Solar XXI

Tendo por base a revisão bibliográfica, utilizamos um modelo de redes neurais do tipo NARX (*Nonlinear Autoregressive with Exogenous Inputs*). Para não saturar os neurónios, fizemos um pré-processamento dos dados fornecidos antes da sua importação para treino das diferentes redes.

Tendo em conta os diferentes estudos consultados, e as sugestões dos diferentes autores para estudar dados desta natureza, começamos por ajustar o intervalo de tempo entre cada amostra. O intervalo de tempo adotado foi de 15 minutos. Em seguida, separamos os dados em dois conjuntos distintos, o de treino e o de validação. Enquanto o conjunto de treino abrangeu os anos compreendidos entre 2015 e 2017, o conjunto de validação centrou-se apenas no ano de 2018, permitindo a avaliação dos modelos utilizando informação que não se encontra incorporada no conjunto de treino.

A última tomada de decisão durante o pré-processamento dos dados foi a escolha do intervalo de tempo considerado para os conjuntos de treino e validação da rede. Ao observar todos os meses, e centrando-nos no pior caso presente, decidimos que as horas escolhidas deveriam estar compreendidas entre as 5h e as 21h. Esta decisão baseou-se no facto de a energia produzida pelo sistema fora do intervalo adotado ser praticamente nula, o que poderia causar perturbações na fase de treino, bem como aumentar a complexidade do sistema desenvolvido.

### 3.1.1 Escolha do atraso da rede

Sabendo que a rede neuronal escolhida tem diversas aplicabilidades, como por exemplo, prever valores futuros de uma série temporal  $y(t)$ , segundo os valores passados dessa mesma série e segundo os valores passados de uma outra série  $x(t)$ , é necessário estimar o atraso imposto aos valores passados antes de se iniciar o processo de treino de uma rede neuronal, uma vez que representa o número de horas/minutos que a rede utiliza para realizar a previsão.

Procurando alcançar o mínimo valor do erro quadrático médio (EQM, de modo a aferir o atraso a que esse número corresponde, decidimos recorrer a uma metodologia baseada na “tentativa e erro”. O mês escolhido para estes testes foi o mês de abril.

De forma a encontrar o melhor resultado, a quantidade de neurónios presentes na camada oculta da rede durante esta fase de testes manteve-se inalterada, com valor igual a 10. Combinando este parâmetro com diversos valores para o atraso, é possível alcançar a solução ótima.

Em primeiro lugar foi estimado o atraso a utilizar na rede neuronal que tem como finalidade a previsão da temperatura em graus Celcius. Testamos dezasseis opções, onde se incluíram as doze últimas horas, ou seja, valores de atraso de  $d = 4, 8, 12, 16, 20, 24, 28, 32, 36, 40, 44$  e  $48$ . Também efetuamos testes referentes a 12, 14, 16 e 24 horas, porém, como é possível observar no gráfico que segue a melhor combinação entre atraso e camadas ocultas atingida, ocorreu com um valor de  $d = 32$ , ou seja, com 8 horas anteriores de dados.




Gráfico 1 - EQM obtido para cada atraso no preditor da temperatura

Tal como fizemos para a temperatura, também para a irradiância testamos o atraso de modo a procurar de novo a solução ótima. Utilizamos também aqui os mesmos dezasseis valores de atraso empregues no estudo da temperatura e aplicamos os mesmos testes. Obtivemos desta forma, os valores adequados a utilizar no desenvolvimento do modelo da rede. No gráfico abaixo, podemos observar que o menor valor obtido para o erro quadrático médio ocorreu com um  $d=24$ , ou seja, com 6 horas anteriores de dados.




Gráfico 2 - EQM obtido para cada atraso no preditor da irradiância

### 3.1.2 Ferramenta utilizada

A toolbox do Matlab foi o principal instrumento de apoio à criação dos modelos de previsão que utilizamos. Esta ferramenta apresenta uma interface gráfica bastante acessível, com diversas opções de escolha em relação às propriedades constituintes da rede. Desde o método utilizado durante o processo de treino, da métrica de avaliação da performance dos modelos, até ao número de neurónios presentes em cada camada oculta da rede. Na figura que segue é possível observar a interface acima mencionada, bem como as diferentes características presentes na escolha da topologia da rede.

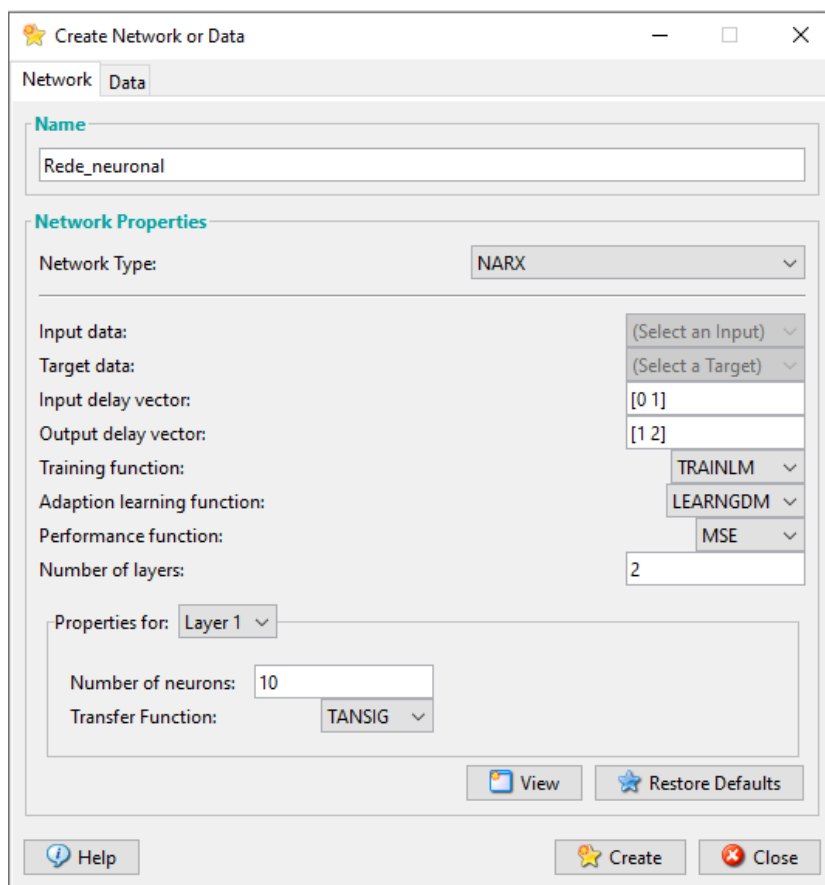


Figura 12 - Interface gráfica de apoio à criação dos modelos de previsão

Durante a fase de treino o algoritmo aplicado foi o de *Levenberg-Marquardt*. Quando comparado com outros algoritmos, a utilização deste em particular fornece privilégios à rede em treino, pois combina vantagens do método do gradiente descendente simples com o algoritmo do método de *Newton*, providenciando não só um desempenho sólido como também uma rápida convergência para uma solução dentro dos limites considerados como aceitáveis.

Considerando ambas as fases, “fase de treino” e “fase de teste”, utilizamos duas topologias distintas no desenvolvimento dos vários modelos de previsão, sendo elas a “*Open Loop*”, adequada à parte de treino da rede, e a “*Close Loop*”, usada para efetuar a previsão pretendida. Nas figuras seguintes é possível observar as duas topologias referidas.

Na figura 12, é exibida a rede em “*Open Loop*”, com 10 neurónios presentes na camada oculta, onde as variáveis de entrada são variáveis exógenas, e as de saída são variáveis endógenas. É também possível constatar que durante o uso da rede com esta arquitetura não existe qualquer tipo de realimentação.






Figura 13 - Topologia em *Open Loop*




Figura 14 - Topologia em *Closed Loop*

Na figura anterior é possível constatar que a grande distinção entre as duas topologias é a realimentação efetuada no segundo caso, ou seja, na arquitetura referente ao “*Close Loop*”. Este *feedback* juntamente com o número de neurónios na camada oculta e com as funções de transferência, influenciam acentuadamente o processo de previsão.

Relativamente às funções de transferência, decidimos utilizar a tangente hiperbólica entre a camada de saída e a camada oculta, devido ao escalamento que apresenta, calculando os dados de saída da rede a partir dos dados de input. Em relação à camada de saída consideramos que devia aplicar-se uma função de transferência linear, apresentando os dados tanto no final da camada oculta como no final da camada de saída, prevenindo um aumento da complexidade dos sistemas desenvolvidos.

### 3.2 Preditores

Para o conjunto de treino usamos os dados relativos aos anos compreendidos entre 2015 e 2017. Os dados do ano de 2018, por não terem sido englobados no conjunto anterior, foram aproveitados para o conjunto de validação.

Para efetuar os testes iniciais, foi necessário escolher o mês que iria servir de apoio à construção dos restantes modelos. A decisão foi tomada apenas com base na ordem alfabética pela qual estão organizados, tendo recaído sobre o mês de abril, uma vez que é o primeiro da lista.

De acordo com o número de neurónios presentes na camada oculta, para que seja possível analisar o resultado e influência que estes possuem durante o processo de treino de obtenção dos vários preditores essenciais ao estudo, foram testadas as redes com 5, 8, 10, 12 e 15 neurónios na camada oculta. Tal como a utilização de mais neurónios em cada camada oculta, também o uso de mais que uma camada deste tipo aumenta a complexidade do sistema bem como o número de pesos necessários até a rede atingir uma solução que cumpra os parâmetros aceitáveis.

Relativamente aos conjuntos de treino, seguimos a mesma lógica, isto é, testamos conjuntos com 15, 20, 25 e 30 dias de dados, com o intuito de desvendar a melhor combinação entre número de neurónios presentes na camada oculta e dimensão do conjunto de treino para cada mês.

### 3.2.1 Temperatura

Aplicando as medidas especificadas anteriormente em relação ao número de neurónios e conjunto de treino a utilizar, efetuamos os diferentes testes para o preditor da temperatura.

Utilizamos como parâmetros de entrada as horas diárias compreendidas entre as cinco da manhã e as nove da noite, dispostas em intervalos de quinze minutos, e como saída os valores de temperatura correspondentes aos dados de entrada. Desta forma foi possível desenvolver o modelo pretendido.

Para cada valor de H (número de neurónios presentes na camada oculta), efetuaram-se os testes programados, apenas variando o conjunto de treino utilizado.

Como o comportamento da rede neuronal pode, por vezes, ser imprevisível e efetuar cálculos de pesos errados, levando a previsões com resultados inconclusivos, procuramos avaliar a melhor combinação entre parâmetros, guardando os cinco melhores resultados da avaliação do desempenho da rede, que estivessem compreendidos abaixo dos 10% de erro.

Este desempenho, por sua vez, é avaliado pelos valores do erro quadrático médio resultantes da previsão, sendo então possível estabelecer uma relação entre o erro quadrático médio e as diferentes combinações de parâmetros usados no treino, ao calcular a média dos resultados atingidos. No gráfico que segue podemos observar a variação do erro quadrático médio consoante o número de neurónios presentes na camada oculta da rede e o conjunto de treino utilizado, para o mês de abril.




Gráfico 3 - EQM do preditor de temperatura para Abril

O preditor usado para o mês refletido no gráfico, serviu de base para os restantes meses. Seguimos assim, uma metodologia semelhante, importando as variáveis relativas a cada um dos meses para o espaço de trabalho, o que permitiu realizar as alterações necessárias, efetuar a previsão e guardar os resultados obtidos.

### 3.2.2 Irradiância

Tendo por base o procedimento aplicado para o preditor de temperatura, decidimos, para o processo de previsão da irradiância seguir o mesmo método.

Como parâmetro de entrada de rede foi novamente considerado o intervalo temporal desde as cinco horas da manhã até às nove horas da noite, disposto em intervalos de quinze minutos. Porém, nesta fase, como variáveis de saída foram utilizados os valores de irradiância adequados, visto que ambos os parâmetros têm de apresentar a mesma dimensão em relação aos dados.

Uma vez mais, para diferentes valores de H (número de neurónios presentes na camada oculta), apenas alterando a dimensão do conjunto do treino, realizaram-se os testes pretendidos, com a finalidade de desenvolver um preditor para a irradiância.

Seguindo a mesma metodologia empregue no preditor anterior, também neste caso, a rede para além de possuir a capacidade de produzir e apresentar resultados pertinentes, poderá também exibir soluções bastante descabidas, prejudicando o desenvolvimento do modelo. De forma a reduzir

ou eliminar esta possibilidade, apenas os valores atingidos que se encontrassem abaixo de 10% em relação ao erro quadrático médio foram aproveitados e registados.




Gráfico 4 - EQM do preditor de irradiância para Abril

No gráfico que segue podemos observar os diferentes valores do erro quadrático médio consoante o conjunto de treino utilizado e número de neurónios presentes na camada oculta.

Em seguida, apresentamos os modelos de previsão para os restantes meses do ano, tanto para a temperatura como para a irradiância. Deste modo é possível retirar conclusões acerca do conjunto de treino a utilizar no processo de construção do modelo do último preditor.

### 3.2.3 Produção Fotovoltaica

Neste ponto, após o treino dos preditores anteriormente referidos, temperatura e irradiância, uma vez que servirão como variáveis de entrada da rede elaborada, vamos explicar a estratégia utilizada no desenvolvimento do preditor final, que é a produção fotovoltaica.

Em primeiro lugar, foi analisado o erro quadrático médio tanto do preditor da temperatura como do preditor da irradiância, com o intuito de decidir qual o conjunto de treino e qual o número de neurónios a aplicar na previsão destes valores.

Em seguida, na parte de treino dos modelos, os valores de temperatura e irradiância foram utilizados como variáveis de entrada, e consequentemente, a produção fotovoltaica correspondente foi adotada como a variável de saída a usar. Uma vez mais o intervalo temporal escolhido encontra-se compreendido entre as cinco horas da manhã e as nove horas da noite.

Quanto ao número de dias para o conjunto de treino, decidimos usar um padrão temporal correspondente a 25 dias, por condicionalismos do programa usado (MATLAB). Este programa não permitiu que o vetor dos dados de entrada apresentasse a mesma dimensão que o vetor dos dados de saída o que comprometia uma medição a 30 dias, daí que tenhamos optado por uma medição a 25 dias, que nos permitiu ultrapassar o problema anterior.

Após este processo, procedeu-se efetivamente ao treino das várias redes em questão. Considerando o conjunto de treino estabelecido e apenas variando o valor do número de neurónios presentes na camada oculta entre 5, 8, 10, 12 ou 15, registaram-se os cinco melhores valores do erro quadrático médio que se encontrassem abaixo de 25%, com a finalidade de avaliar a melhor performance obtida para cada mês.

A decisão de utilizar apenas os resultados abaixo de um certo patamar para analisar a performance, provém da imprevisibilidade do cálculo dos pesos que a rede efetua durante a fase de treino. Comparativamente aos dois preditores anteriores, temperatura e irradiância, onde o patamar se encontrava nos 10%, o aumento para 25% advém da utilização de duas variáveis de entrada ao invés de apenas uma, e da dificuldade encontrada para alcançar valores dentro dos parâmetros aceitáveis relativamente a determinados meses.

No gráfico é possível observar o erro quadrático médio obtido variando o valor de H (número de neurónios presentes na camada oculta), para o mês de abril.




Gráfico 5 - EQM do preditor da produção fotovoltaica em Abril

Pela análise do gráfico, podemos observar que os valores registados em relação ao erro quadrático médio, comparativamente aos preditores da temperatura e da irradiância aumentaram consideravelmente. Facto que pode ser explicado pela maior imprevisibilidade dos dados em estudo, nomeadamente a produção fotovoltaica, uma vez que existem diversos fatores envolvidos no processo de produção de energia não contabilizados neste estudo.

## 4. Apresentação dos modelos em estudo

Nesta parte do trabalho iremos apresentar os resultados obtidos relativamente aos estudos efetuados para os diferentes modelos criados. No primeiro ponto será efetuada uma apresentação mensal através de tabelas e quadros com os valores médios para cada conjunto de treino, seguindo a mesma lógica. Começamos por evidenciar os resultados relativos à variação do erro quadrático médio consoante o número de neurónios na camada oculta, tanto para a temperatura como para a irradiância. Seguidamente, é feita a comparação entre a produção fotovoltaica real e prevista pelos diferentes modelos.

Para comparar os valores previstos e reais da produção fotovoltaica, foi necessário escolher o número de neurónios presentes na camada oculta da rede. Tomando por base os valores reais de temperatura e irradiância e variando o parâmetro relativo aos neurónios entre 5, 8, 10, 12 e 15, foi escolhido o valor ótimo a usar, ou seja, o que apresente menor erro quadrático médio, sendo assim possível prever a produção fotovoltaica para um dia de cada um dos meses estudados.

Num segundo ponto faremos uma compilação dos dados através de uma tabela que indica qual a combinação mais favorável entre o conjunto de treino a considerar e o número de neurónios contidos na camada oculta do modelo desenvolvido, relativamente ao preditor da temperatura e de irradiância. Terminamos com a apresentação de um gráfico com a comparação entre a produção fotovoltaica real e prevista para cada um dos meses do ano estudado.

### 4.1 Apresentação mensal

#### 4.1.1 Janeiro

No gráfico 6 podemos observar a variação do erro quadrático médio relativamente ao preditor da temperatura para o mês de janeiro, considerando os diferentes conjuntos de treino estudados e tendo em conta o atraso da rede previamente escolhido.




Gráfico 6 - EQM do predictor de temperatura para Janeiro

Por observação do gráfico, é possível constatar que os valores do erro quadrático médio oscilam entre 0,02 e 0,08, que os modelos com 5, 8, 10 e 12 neurónios se desenvolvem em torno de valores mais próximos (oscilando entre 0,02 e 0,05), enquanto que o modelo com 15 neurónios presentes na camada oculta da rede, é aquele que apresenta valores mais elevados (oscila entre 0,04 e 0,08) ou seja é o modelo que apresenta pior performance. Podemos ainda observar que o erro quadrático médio entre os 15 e os 25 dias apresenta uma trajetória descendente independentemente do número de neurónios envolvidos, subindo em todos eles no conjunto de treino dos 25 para os 30 dias. Contrariamente, os melhores desempenhos ocorreram com um número de neurónios igual a 8 ou a 10, obtendo com estes valores, o menor valor do erro quadrático médio tanto para o conjunto composto por 20 dias como para o de 25 dias. Curiosamente se nos centrarmos nos valores obtidos a 30 dias, constatamos que o conjunto de neurónios que obtém valores no erro quadrático médio mais baixos é o conjunto de 12 neurónios que a 15 dias era o que estava no valor mais elevado.

Na tabela que se segue podemos observar os valores numéricos que nos ajudam a perceber melhor as curvas apresentadas no gráfico 6.



Tabela 1 - Média do EQM do preditor da temperatura para Janeiro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
5	0,04082	0,04022	0,03172	0,03294
8	0,04156	0,02694	<b>0,02442</b>	0,0454
10	0,03854	0,03718	0,02604	0,0385
12	0,04632	0,04586	0,02796	0,02922
15	0,07292	0,047	0,04134	0,06658
<b>Média</b>	0,04803	0,0394	<b>0,03029</b>	0,04252

Pela observação dos valores da tabela podemos verificar que o melhor conjunto de treino é o de 25 dias, uma vez que é aquele que obtém uma média mais baixa para o valor do erro quadrático médio (0,03029) para as combinações utilizadas. Quanto ao número de neurónios a usar o melhor resultado (0,02442) foi obtido com 8 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 8 neurónios na camada oculta e um conjunto de treino de 25 dias.

Também para o preditor da irradiância é necessário avaliar quais os parâmetros a utilizar.




Gráfico 7 - EQM do preditor de irradiância para Janeiro

No gráfico 7, observamos que os valores obtidos para o erro quadrático médio no preditor da irradiância para o mês de janeiro encontram-se entre os 0,04 e os 0,08, e que os modelos apresentam um comportamento semelhante para os diferentes conjuntos de treino, uma vez que a oscilação entre os valores não é muito diferente. Este facto é possível observar analisando as trajetórias de todas as curvas, pois manifestam o mesmo comportamento, ou seja, uma trajetória descendente desde os 15 até aos 25 dias e uma trajetória ascendente até aos 30 dias. Observamos também que o modelo com o menor valor de erro quadrático médio para um conjunto de treino de 15 dias, (H=8), apresenta o valor mais elevado quando é considerado o conjunto de 30 dias, enquanto que o modelo que tem um valor de erro quadrático médio mais elevado no conjunto de treino de 15 dias, (H=12), exibe o segundo melhor valor para o conjunto de 30 dias.

A tabela seguinte permite escolher a melhor combinação entre o conjunto de treino e o número de neurónios presentes na camada oculta da rede.

Tabela 2 - Média do EQM do preditor da irradiância para Janeiro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,06636	0,04828	<b>0,04764</b>	0,07128
<b>8</b>	0,0511	0,0498	0,05204	0,07436
<b>10</b>	0,0697	0,06592	0,05202	0,06592
<b>12</b>	0,0719	0,0609	0,05506	0,06662
<b>15</b>	0,05666	0,05578	0,05506	0,07054
<b>Média</b>	0,06314	0,05614	<b>0,05236</b>	0,06974

Por análise da tabela 2, constatamos que o resultado da média mais baixo relativamente ao erro quadrático médio se verifica no conjunto de treino de 25 dias (0,04764). Quanto ao número de neurónios a usar o melhor resultado (0,02442) foi obtido com 5 neurónios.

Assim sendo, é possível concluir que a melhor combinação de parâmetros a utilizar neste preditor acontece com um conjunto de treino de 25 dias com 5 neurónios presentes na camada oculta da rede.

Em seguida, aplicando as combinações decididas para os 2 preditores em questão, foram estimados os valores para um mesmo dia de janeiro do ano de 2018, de modo a serem empregues como variáveis de entrada no modelo de previsão da produção fotovoltaica.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de janeiro podem ser observados no gráfico 8.




Gráfico 8 - Produção fotovoltaica por hora real e prevista para Janeiro

Analisando o gráfico anterior, que apresenta a comparação entre os valores estimados e reais médios por hora para a produção fotovoltaica para um dia de janeiro de 2018, podemos observar que os valores da produção fotovoltaica se situam entre os 0W e os 9000W, sendo estes valores superiores na produção prevista. Podemos também observar que quer a produção real, quer a produção fotovoltaica prevista seguem um padrão comum, isto é, têm um valor praticamente inexistente nas extremidades e um valor mais elevado ao centro. Um outro dado comum é que os valores crescem entre as 6h e as 13h, decrescendo a partir dessa hora até às 21h. Podemos ainda observar que ao longo de toda a medição, os valores da previsão são sempre superiores aos reais, sendo encontradas as maiores diferenças entre o real e o previsto às 12h e 13h e a partir das 17h, enquanto que as diferenças foram praticamente inexistentes às 14h e mínimas às 15h.

#### 4.1.2 Fevereiro

Para encontrar a melhor combinação entre o número de neurónios presentes na camada oculta e o conjunto de treino a utilizar, seguimos a mesma abordagem do mês anterior, com exceção dos conjuntos de treino a utilizar. Como fevereiro apresenta no máximo 29 dias por mês, foi excluído o conjunto de treino relativo a 30 dias para este mês.

No gráfico 9, podemos observar a variação do erro quadrático médio para o preditor da temperatura no mês de fevereiro.




Gráfico 9 - EQM do preditor de temperatura para Fevereiro

Analisando o gráfico, é possível observar que os valores do erro quadrático médio variam entre 0,03 e 0,08, que o comportamento de todos os modelos é semelhante, apresentando uma trajetória descendente relativamente ao erro quadrático médio entre o conjunto de 15 dias e o conjunto de 20, e uma trajetória ascendente dos 20 para os 25 dias. Constatamos também que a melhor performance é atingida pelo modelo que contém 12 neurónios na camada oculta da rede (oscilando entre os 0,03 e os 0,05), enquanto que os modelos com pior performance são os que compreendem na camada oculta 5 e 15 neurónios (oscilam entre 0,05 e 0,08), apresentando para todos os conjuntos de treino os valores mais elevados.

Na seguinte tabela conseguimos observar os valores presentes no gráfico 9, para uma melhor compreensão das curvas apresentadas bem como dos resultados obtidos.

Tabela 3 - Média do EQM do preditor da temperatura para Fevereiro

Neurónios na camada oculta	Conjunto de treino		
	15 dias	20 dias	25 dias
<b>5</b>	0,07518	0,05564	0,05684
<b>8</b>	0,0678	0,04348	0,05072
<b>10</b>	0,06126	0,04292	0,05418
<b>12</b>	0,03752	<b>0,0369</b>	0,04042
<b>15</b>	0,07056	0,05384	0,05498
<b>Média</b>	0,06246	<b>0,04656</b>	0,05142

Observando os valores presentes na tabela é notório que o conjunto de treino de 20 dias apresenta uma média mais baixa para o valor do erro quadrático médio em comparação com os restantes conjuntos (0,04656). Quanto ao número de neurónios a usar o melhor resultado (0,0369) foi obtido com 12 neurónios.

Assim sendo, é possível concluir que, para este preditor, a combinação de parâmetros a utilizar consiste num conjunto de treino de 20 dias com 12 neurónios presentes na camada oculta da rede.

Tal como procedido para a temperatura, também para a irradiância foi seguido o mesmo processo, como podemos observar no seguinte gráfico.




Gráfico 10 - EQM do preditor de irradiância para Fevereiro

Pela análise do gráfico 10, observamos que os valores obtidos para o erro quadrático médio estão compreendidos entre 0,02 e 0,07, e que todos os modelos apresentam valores bastante próximos (variando entre os 0,02 e os 0,045), com exceção do modelo com 5 neurónios presentes na camada oculta da rede, que para o conjunto de treino que contém 30 dias apresenta um valor para o erro quadrático médio a rondar os 0,07. É também possível visualizar a semelhança na trajetória de todas as curvas, visto que apresentam um declive negativo dos 15 aos 20 dias e um declive positivo entre os 20 e os 25 dias. A melhor performance atingida é claramente obtida pelo modelo que contém 15 neurónios presentes na camada oculta da rede, uma vez que para todos os conjuntos de treino é o que apresenta o valor do erro quadrático médio mais reduzido.

A tabela seguinte serve de apoio a uma melhor compreensão do gráfico e é fundamental para a escolha do conjunto de treino a utilizar.

Tabela 4 - Média do EQM do preditor da irradiância para Fevereiro

Neurónios na camada oculta	Conjunto de treino		
	15 dias	20 dias	25 dias
5	0,02888	0,02812	0,06792
8	0,03622	0,03498	0,04106
10	0,03298	0,03154	0,04462
12	0,03404	0,0344	0,04078
15	0,0271	<b>0,02274</b>	0,0304
<b>Média</b>	0,03184	<b>0,03035</b>	0,04495

Analisando os valores da média do erro quadrático médio presentes na tabela, podemos concluir que o resultado mais baixo foi obtido para o conjunto que contém 20 dias, (0,03035), comparativamente aos restantes. Quanto ao número de neurónios a usar o melhor resultado (0,02274) foi obtido com 15 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 15 neurónios na camada oculta e um conjunto de treino de 20 dias.

Tendo por base as decisões tomadas, efetuamos a previsão tanto da temperatura como da irradiância para um mesmo dia do mês de fevereiro, de modo a estimar a produção de energia fotovoltaica para o mês em questão.




Gráfico 11 - Produção fotovoltaica por hora real e prevista para Fevereiro

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de fevereiro podem ser observados no gráfico 11.

Pela análise do gráfico anterior, que diz respeito à comparação entre os valores reais e previstos médios por hora para a produção fotovoltaica para um dia de fevereiro de 2018, constatamos que os valores da produção estão compreendidos entre os 0W e os 7000W, sendo que os valores reais se apresentam superiores em quase todas as horas de medição. Constatamos também que, quer a produção real quer a produção prevista manifestam um comportamento semelhante, visto que apresentam um aumento dos valores até às 14h, onde o valor de ambas é máximo, e a partir dessa hora até ao final das horas de medição é observável um decréscimo dos resultados. É possível ainda observar que ao longo de toda a medição os valores reais são superiores aos valores previstos, com exceção do intervalo das 9h às 11h, e novamente às 21h, onde ambos os valores são quase nulos.



### 4.1.3 Março

No seguinte gráfico observamos a variação do erro quadrático médio para o mês de março relativamente ao preditor da temperatura, consoante os diferentes conjuntos de treino e tendo em conta o atraso da rede considerado anteriormente.




Gráfico 12 - EQM do preditor de temperatura para Março

Por constatação do gráfico 12, é possível verificar que os valores do erro quadrático médio variam entre 0,02 e 0,14, que os modelos que contêm 12 e 15 neurónios apresentam um comportamento muito semelhante, onde ambos apresentam o seu valor mais reduzido para o conjunto de treino de 25 dias, e que o maior resultado para o erro quadrático médio é obtido com um conjunto de treino de 15 dias e com 8 neurónios presentes na camada oculta da rede. Podemos também observar que o erro quadrático médio de todos os modelos, à exceção do modelo onde o número de neurónios é igual a 12, apresentam uma trajetória descendente entre os 15 e os 20 dias, e excluindo o modelo com 5 neurónios na camada oculta, também entre os 20 e os 25 dias todos os modelos exibem a mesma trajetória descendente. Curiosamente, se observarmos o comportamento da curva relativa ao número de neurónios igual a 8, verificamos que no conjunto de treino de 15 dias exhibe o pior resultado, enquanto que para 30 dias verifica o segundo valor mais reduzido do erro quadrático médio.

Na tabela 5, observamos os valores presentes nas curvas do gráfico anterior, de modo a compreender melhor os resultados obtidos.

Tabela 5 - Média do EQM do preditor da temperatura para Março

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,05084	0,02542	0,0467	0,05146
<b>8</b>	0,12895	0,06144	0,04242	0,05538
<b>10</b>	0,09064	0,05204	0,04288	0,05538
<b>12</b>	0,05202	0,06104	<b>0,03488</b>	0,06016
<b>15</b>	0,05746	0,05618	0,03504	0,06832
<b>Média</b>	0,07598	0,05122	<b>0,04038</b>	0,05814

Constatando os resultados obtidos na tabela, observamos que o conjunto de treino que apresenta a média mais baixa para o valor do erro quadrático médio é o de 25 dias (0,04038), tendo sido escolhido como conjunto a utilizar. Quanto ao número de neurónios a usar o melhor resultado (0,03488) foi obtido com 12 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 12 neurónios na camada oculta e um conjunto de treino de 25 dias.

Seguindo o mesmo raciocínio, também foi necessário estudar a combinação a utilizar para a previsão da irradiância, e no gráfico 13, podemos observar a variação do erro quadrático médio no preditor da irradiância para o mês de fevereiro tendo em consideração o atraso anteriormente determinado.




Gráfico 13 - EQM do preditor de irradiância para Março

Observando o gráfico anterior, é possível verificar que os valores do erro quadrático médio deste preditor se encontram entre os 0,01 e 0,05, e que, apesar de não apresentarem grande oscilação ou discrepância, nenhum dos modelos apresenta um comportamento idêntico, não sendo possível concluir a partir do gráfico qual o melhor conjunto de treino a utilizar.

É também possível observar que o modelo com o valor do erro quadrático médio obtido mais elevado para o conjunto de 15 dias, é o mesmo que apresenta o menor valor de erro no conjunto de treino de 30 dias, ou seja, com 10 neurónios presentes na camada oculta da rede. Por outro lado, o modelo que contém 5 neurónios na camada oculta, obteve o melhor resultado relativamente ao erro quadrático médio no conjunto de 15 dias e o segundo pior resultado no conjunto de treino de 30 dias.

A seguinte tabela serviu de base à tomada de decisão para o preditor em questão.

Tabela 6 - Média do EQM do preditor da irradiância para Março

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,02716	0,03888	0,03582	0,03166
<b>8</b>	0,0436	0,0445	0,0191	0,0306
<b>10</b>	0,04876	0,02572	0,0274	<b>0,01428</b>
<b>12</b>	0,0374	0,03308	0,03308	0,01734
<b>15</b>	0,04696	0,0375	0,02656	0,034
<b>Média</b>	0,04078	0,03594	0,02839	<b>0,02558</b>

Pela análise efetuada aos resultados obtidos, o conjunto de treino que apresenta o menor valor para a média do erro quadrático médio é o de 30 dias (0,02558). Quanto ao número de neurónios a usar o melhor resultado (0,01428) foi obtido com 10 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 10 neurónios na camada oculta e um conjunto de treino de 30 dias.

Após a escolha da melhor combinação de parâmetros, tanto para a temperatura como para a irradiância para um dia do mês de março, foi realizada a previsão destes preditores para o mês em questão, com a finalidade de estimar a produção fotovoltaica.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de março podem ser observados no gráfico 14.




Gráfico 14 - Produção fotovoltaica por hora real e prevista para Março

Por análise do gráfico 14, que representa a comparação entre os valores previstos e reais médios por hora da produção fotovoltaica para um dia do mês de março de 2018, é possível observar que os valores reais estão compreendidos entre os 0W e os 6500W, enquanto que os resultados previstos pelo modelo desenvolvido se encontram entre os 0W e os 9000W.

Conseguimos constatar também que ao longo de todas as horas de medição antes das 17h, a produção prevista ultrapassa sempre a produção real efetuada, com maior ênfase das 10h às 13h. Entre as 17h e as 18h observa-se um decréscimo acentuado dos valores previstos passando a apresentar valores inferiores à produção real, invertendo-se de novo a tendência a partir das 19h onde os valores previstos voltam a ser superiores aos reais

#### 4.1.4 Abril

No gráfico 15 é possível visualizar a variação do erro quadrático médio para as várias combinações de teste utilizadas no mês de abril, tendo em consideração o atraso da rede escolhido anteriormente.




Gráfico 15 - EQM do preditor de temperatura para Abril

Pelo gráfico constatamos que, os valores obtidos para o erro quadrático médio oscilam entre 0,01 e 0,04, e que os modelos com 8 e 10 neurónios apresentam uma performance superior comparativamente aos modelos com 5, 12 e 15 neurónios. Esta observação pode ser efetuada uma vez que em todos os conjuntos de treino os resultados mínimos foram alcançados com recurso a esses 2 modelos, mas também porque apenas para o conjunto de 25 dias é que foi obtido um valor acima de 0,025 para o erro quadrático médio. Contrária e consecutivamente, os modelos com 5, 12 e 15 neurónios apresentam uma performance pior.

Apenas analisando os resultados expressos no gráfico, não é possível concluir qual a melhor combinação de parâmetros a utilizar neste preditor. Apoiamo-nos desta forma na tabela 7 onde são apresentados os valores correspondentes a cada um dos pontos presentes no gráfico, e também a média resultante para cada conjunto dos erros quadráticos médios registados, para conseguir saber qual a melhor combinação.

Tabela 7 - Média do EQM do preditor da temperatura para Abril

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
5	0,0227	0,03872	0,03124	0,02942
8	<b>0,01454</b>	0,01038	0,02832	0,01944
10	0,02186	0,02354	0,0158	0,0195
12	0,03268	0,02728	0,02308	0,0214
15	0,02786	0,03296	0,0272	0,031
<b>Média</b>	<b>0,02393</b>	0,02658	0,02513	0,02415

Observando a tabela anterior, mais especificamente a média do erro quadrático médio para cada conjunto de treino, verificamos que o melhor a utilizar é o conjunto de 15 dias, visto apresentar o valor mais baixo relativamente à média calculada (0,02393). Quanto ao número de neurónios a usar o melhor resultado (0,01454) foi obtido com 8 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 8 neurónios na camada oculta e um conjunto de treino de 15 dias.

O procedimento adotado para a temperatura foi também seguido para aferir a combinação usada para o preditor da irradiância, e podemos visualizar os valores obtidos para o erro quadrático médio no gráfico 16.




Gráfico 16 - EQM do preditor de irradiância para Abril

Por observação do gráfico é possível verificar que os valores do erro quadrático médio para os diferentes conjuntos variam entre 0,01 e 0,05, que os modelos referentes a 8, 10 e 12 neurónios apresentam pior performance, desenvolvendo-se em torno de valores mais próximos (oscilando entre 0,025 e 0,045), que o modelo referente a 15 neurónios para os conjuntos de 25 e 30 dias também apresenta uma fraca performance, quando comparado com o modelo que compreende 5 neurónios na camada oculta, uma vez que apresenta resultados muito favoráveis e sempre abaixo de 0,025 qualquer que seja o conjunto de treino considerado. É possível constatar também que o modelo de 15 neurónios apesar de apresentar o melhor resultado para o erro quadrático médio no conjunto de 15 dias, apresenta um dos piores valores para o conjunto de 30 dias.

Com recurso à seguinte tabela foi possível escolher tanto o conjunto de treino como o número de neurónios presentes na camada oculta da rede desenvolvida, analisando a média do erro quadrático médio para os diferentes conjuntos considerados.



Tabela 8 - Média do EQM do preditor da irradiância para Abril

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,01968	0,0225	<b>0,01176</b>	0,01784
<b>8</b>	0,0341	0,03654	0,02768	0,0299
<b>10</b>	0,0252	0,0305	0,02472	0,04052
<b>12</b>	0,02768	0,04484	0,02574	0,0361
<b>15</b>	0,01948	0,01108	0,03216	0,03488
<b>Média</b>	0,02523	0,02909	<b>0,02441</b>	0,03185

Por constatação dos valores verificamos que o melhor conjunto a utilizar para o desenvolvimento do modelo foi um conjunto de treino com 25 dias, pois a média do erro quadrático médio foi a mais baixa obtida para o preditor deste mês (0,02441). Quanto ao número de neurónios a usar o melhor resultado (0,01176) foi obtido com 5 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 5 neurónios na camada oculta e um conjunto de treino de 25 dias.

Posteriormente, e tendo por base as opções escolhidas tanto para o preditor da temperatura como para o preditor da irradiância, estimaram-se os valores destas duas variáveis para um mesmo dia do mês de abril de 2018, com a finalidade de os utilizar na previsão da produção fotovoltaica como dados de entrada da rede neuronal desenvolvida.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de abril podem ser observados no gráfico 17.




Gráfico 17 - Produção fotovoltaica por hora real e prevista para Abril

Por observação do gráfico, que representa a comparação entre os valores previstos e reais médios por hora para a produção fotovoltaica num dia de abril de 2018, verificamos que os valores se situam entre os 0W e os 1400W. Tanto a produção real como a prevista seguem um padrão semelhante, na medida de que os seus valores são mínimos nas primeiras e ultimas horas de medição, e valores mais elevados na parte central do gráfico. Os resultados revelam, no entanto, que os valores relativos à produção prevista são mais elevados entre as 6h e as 12h e a partir das 18h até às 21h, invertendo-se os resultados entre as 13h e as 17h, onde os valores da produção real são superiores.

#### 4.1.5 Maio

No seguinte gráfico observamos a variação do erro quadrático médio para o preditor da temperatura do mês de maio, tendo em atenção o atraso escolhido previamente e os diferentes conjuntos de treino considerados.




Gráfico 18 - EQM do preditor de temperatura para Maio

Analisando o gráfico 18, constatamos que os valores obtidos relativamente ao erro quadrático médio encontram-se compreendidos entre 0,02 e 0,06, observando uma relativa semelhança no comportamento dos diferentes modelos, na medida que, apenas com recurso ao gráfico apresentado não é possível chegar a uma conclusão de qual o modelo a utilizar e de quantos neurónios estão presentes na camada oculta da rede. É possível também constatar que todos os modelos apresentam uma melhoria da performance do conjunto de treino de 15 dias para os conjuntos de 25 e 30 dias, uma vez que se verifica uma diminuição do erro quadrático médio.

Pelo gráfico, neste caso, é de fácil perceção que o conjunto de treino que apresenta melhores resultados é o de 25 dias, valor esse que pode ser confirmado na tabela 9.

Tabela 9 - Média do EQM do preditor da temperatura para Maio

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,03702	0,03864	0,0309	0,03128
<b>8</b>	0,03012	0,04492	0,02704	0,02838
<b>10</b>	0,04492	0,05448	0,022	0,03182
<b>12</b>	0,04378	0,03602	<b>0,0217</b>	0,02428
<b>15</b>	0,05746	0,05478	0,02916	0,04518
<b>Média</b>	0,04266	0,04577	<b>0,02616</b>	0,03219

Analisando os resultados obtidos e registados na tabela anterior, verificamos que o melhor resultado da média do erro quadrático médio para cada conjunto de treino foi obtido para o conjunto de 25 dias (0,02616). Quanto ao número de neurónios a usar o melhor resultado (0,0217) foi obtido com 12 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 12 neurónios na camada oculta e um conjunto de treino de 25 dias.

Tal como para a temperatura, os mesmos testes foram também realizados para o preditor da irradiância. Os resultados estão indicados no gráfico 19.




Gráfico 19 - EQM do preditor de irradiância para Maio

Pela observação dos resultados é possível constatar que os valores relativos ao erro quadrático médio das previsões efetuadas se encontram entre os 0 e os 0,02, indicando uma grande melhoria na performance quando comparado com os meses anteriores. É também possível observar que o modelo que apresenta o melhor resultado para todos os conjuntos de treino, neste mês, é o que compreende 5 neurónios na camada oculta da rede, uma vez que o erro quadrático médio resultante das previsões efetuadas com este modelo se encontra sempre abaixo de 0,005.

Por outro lado, verificamos também que o modelo com o pior resultado no conjunto de treino de 15 dias apresenta o segundo melhor valor no conjunto de treino de 30 dias, e que o modelo com a segunda melhor performance no conjunto de 15 dias, é o que apresenta a pior performance, aos 30 dias.

Na tabela seguinte, observamos em maior detalhe os resultados obtidos, bem como a média para cada conjunto de treino do erro quadrático médio obtido para cada combinação.

Tabela 10 - Média do EQM do preditor da irradiância para Maio

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,00306	0,0012908	<b>0,0012619</b>	0,0016822
<b>8</b>	0,01306	0,0088981	0,00442	0,0076138
<b>10</b>	0,0071344	0,00714	0,0064412	0,01156
<b>12</b>	0,00982	0,002621	0,01504	0,0112383
<b>15</b>	0,01046	0,0198	0,0107	0,0114206
<b>Média</b>	0,0087	0,00795	<b>0,00757</b>	0,00870

Pela interpretação dos resultados presentes na tabela, verificamos que o conjunto de treino que apresenta o menor valor para a média do erro quadrático médio é o de 25 dias (0,00757). Quanto ao número de neurónios a usar o melhor resultado (0,0012619) foi obtido com 5 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 5 neurónios na camada oculta e um conjunto de treino de 25 dias.

Posteriormente, tendo em conta as decisões tomadas por base nos resultados obtidos, efetuamos a previsão dos preditores da temperatura e da irradiância para o mês em questão, com o objetivo de estimar a produção fotovoltaica.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de maio podem ser observados no gráfico seguinte.




Gráfico 20 - Produção fotovoltaica por hora real e prevista para Maio

Observando o gráfico 20, que exibe a comparação entre os valores previstos e reais médios por hora para a produção fotovoltaica, verificamos que estão compreendidos entre os 0W e os 3500W, sendo estes valores superiores na produção real durante todas as horas de medição. É também observável que existe um padrão comum entre ambas as produções (real e prevista), apresentando valores mais baixos relativamente à produção nas primeiras e últimas horas de medição, contendo um pico às 14h. Verificamos também que até à hora de pico os valores vão sempre crescendo, e após essa hora, vão sempre decrescendo, contrariamente ao que acontece em certos modelos de previsão já estudados.

#### 4.1.6 Junho

No seguinte gráfico visualizamos a variação do erro quadrático médio para os diferentes conjuntos de treino utilizados e consoante o número de neurónios presentes na camada oculta da rede desenvolvida, considerando o atraso previamente escolhido para a mesma.




Gráfico 21 - EQM do preditor de temperatura para Junho

Pela visualização das curvas referentes aos vários modelos considerados, verificamos que os valores do erro quadrático médio oscilam entre os 0,01 e os 0,08, que os modelos com 5, 8, 10 e 12 neurónios se desenvolvem em torno de valores próximos (oscilando entre 0,01 e 0,05), enquanto que o modelo que compreende 15 neurónios na camada oculta da rede apresenta claramente a pior performance, com valores para o erro quadrático médio entre os 0,05 e os 0,08, ou seja, mais elevados que os valores obtidos para os restantes modelos.

É também possível constatar que entre os conjuntos de 15 e 25 dias, o erro quadrático médio apresenta uma trajetória descendente qualquer que seja o modelo considerado, e que entre os 25 e os 30 dias, a trajetória apresentada, também por todos os modelos, é ascendente.

Com recurso à tabela 11, foi tomada a decisão de qual o conjunto de treino a utilizar, bem como o número de neurónios presente na camada oculta da rede.



Tabela 11 - Média do EQM do preditor da temperatura para Junho

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,05014	0,02288	0,0168	0,01712
<b>8</b>	0,04606	0,02352	<b>0,01648</b>	0,02522
<b>10</b>	0,03796	0,03	0,01984	0,02924
<b>12</b>	0,03278	0,02096	0,02042	0,02214
<b>15</b>	0,03748	0,02858	0,02534	0,02622
<b>Média</b>	0,04088	0,02519	<b>0,01978</b>	0,02399

Observando os resultados obtidos, tendo em consideração a média do erro quadrático médio para os conjuntos testados, verificamos que o valor mais reduzido se verificou com um conjunto de treino de 25 dias (0,01978). Quanto ao número de neurónios a usar o melhor resultado (0,01648) foi obtido com 8 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 8 neurónios na camada oculta e um conjunto de treino de 25 dias.

Do mesmo modo, também para o preditor da irradiância foi necessário escolher os parâmetros a utilizar. Os dados obtidos para o erro quadrático médio estão representados no gráfico 22.




Gráfico 22 - EQM do preditor de irradiância para Junho

Observando o gráfico anterior, constatamos que os valores do erro quadrático médio do preditor da irradiância para os diferentes conjuntos estão compreendidos entre os 0,01 e os 0,035, que as curvas relativas aos modelos que contêm 5 e 15 neurónios na camada oculta da rede têm um comportamento semelhante, com diferença apenas na performance apresentada, visto que os valores resultantes para o modelo com 5 neurónios são bem mais reduzidos comparativamente aos valores apresentados com 15 neurónios, como é possível observar. Verificamos também que o modelo com o valor mais elevado para o erro quadrático médio no conjunto de treino de 15 dias, apresenta o menor valor no conjunto de 25 dias, e que o que tem o valor mais reduzido no conjunto de 15 dias, apresenta o segundo valor mais elevado no conjunto de treino de 30 dias sendo estes os têm 12 e 10 neurónios na camada oculta da rede respetivamente.

Na seguinte tabela verificamos em maior detalhe quais os valores obtidos, assim como a média obtida para cada conjunto relativamente ao erro quadrático médio.

Tabela 12 - Média do EQM do preditor da irradiância para Junho

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,01334	0,01262	0,0119	0,01398
<b>8</b>	0,01624	0,01446	0,01324	0,02332
<b>10</b>	0,01298	0,01772	0,01162	0,02492
<b>12</b>	0,03306	0,03108	<b>0,01148</b>	0,01866
<b>15</b>	0,03062	0,02694	0,02554	0,02644
<b>Média</b>	0,02125	0,02056	<b>0,01476</b>	0,02146

Averiguando os valores do erro quadrático médio contidos na tabela, e efetuando a sua média para cada conjunto de treino, conseguimos concluir qual o conjunto a utilizar na previsão. O valor mais baixo para o preditor em causa foi obtido com um conjunto de treino de 25 dias (0,01476). Quanto ao número de neurónios a usar o melhor resultado (0,01148) foi obtido com 12 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 12 neurónios na camada oculta e um conjunto de treino de 25 dias.

Assim, realizamos a previsão tanto da temperatura como da irradiância com recursos aos preditores desenvolvidos, a fim de comparar a produção fotovoltaica real com a estimada.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de junho podem ser observados no gráfico 23.




Gráfico 23 - Produção fotovoltaica por hora real e prevista para Junho

Analisando o gráfico acima representado, que diz respeito à comparação entre a produção fotovoltaica real e prevista média por hora para um dia do mês de junho de 2018, é possível visualizar que os valores de produção se encontram entre os 0W e os 2500W, e que o padrão seguido tanto pelos valores reais como pelos valores estimados é muito semelhante, ocorrendo um aumento dos valores desde as 6h até às 13h, onde se verifica o pico diário de produção, e um decréscimo desde as 14h até às 21h. Durante todo o intervalo de medição a diferença entre os valores reais e estimados não apresenta muita diferença, ou seja, este modelo apresenta uma boa performance, e os valores estimados ultrapassam os reais das 7h até às 14h, invertendo-se a partir das 15h até às 21h.

#### 4.1.7 Julho

No gráfico abaixo representado é possível observar a variação do erro quadrático médio para o preditor da temperatura do mês de julho, tendo em conta os diferentes conjuntos de treino e o atraso anteriormente considerado.




Gráfico 24 - EQM do preditor de temperatura para Julho

Observando o gráfico 24, podemos observar que os valores do erro quadrático médio para o preditor da temperatura, neste mês, variam entre 0,03 e 0,08, e que apesar de não existir uma diferença significativa nos números apresentado pelos vários modelos, todos eles apresentam um comportamento distinto. Como é possível constatar, o modelo que contém 12 neurónios presentes na camada oculta apresenta o resultado menos favorável no conjunto de treino de 15 dias, porém no conjunto de 20 dias apresenta o resultado com menor valor de erro quadrático médio. Contrariamente, o modelo que compreende 15 neurónios, apresenta o menor valor do erro quadrático médio no primeiro e terceiro conjuntos considerados, o de 15 e o de 25 dias, contudo no conjunto compreendido entre estes, o de 20 dias, apresenta o resultado do erro quadrático médio mais elevado.

Com recurso à tabela seguinte, é possível escolher a melhor combinação a utilizar para o preditor da temperatura para o mês de julho.

Tabela 13 - Média do EQM do predictor da temperatura para Julho

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
5	0,0687	0,0661	0,07678	0,07858
8	0,07062	0,05692	0,0671	0,06066
10	0,06306	0,06314	0,05504	<b>0,04854</b>
12	0,07374	0,052	0,07408	0,05648
15	0,0565	0,06702	0,03822	0,05334
<b>Média</b>	0,06652	0,06104	0,06224	<b>0,05952</b>

A tabela 13, apresenta em maior detalhe os pontos representados no gráfico 24, assim como as médias resultantes dos valores obtidos para o erro quadrático médio para cada conjunto de treino. Quanto ao número de neurónios a usar o melhor resultado (0,04854) foi obtido com 10 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao predictor da temperatura para este mês apresenta 10 neurónios na camada oculta e um conjunto de treino de 30 dias.

Tal como procedido para a temperatura, também para a irradiância é necessário obter qual a melhor combinação de parâmetros a utilizar no desenvolvimento do predictor em causa.




Gráfico 25 - EQM do predictor de irradiância para Julho

Por observação do gráfico anterior, que representa os valores obtidos para o preditor da irradiância relativamente ao erro quadrático médio, é possível verificar que os valores se encontram compreendidos entre 0,01 e 0,06. Em relação aos modelos estudados, observamos 2 tipos diferentes de comportamento. Os que contêm 5, 8 ou 15 neurónios na camada oculta apresentam uma trajetória ascendente do conjunto dos 15 para os 20 dias e dos 25 para os 30 dias, enquanto que dos 20 para os 25 dias a trajetória é descendente. Relativamente aos modelos que compreendem 10 ou 12 neurónios na camada oculta, com exceção da última transição entre conjuntos, dos 25 para os 30 dias, exibem um comportamento semelhante, no qual a primeira opção, com 10 neurónios, tem uma trajetória ascendente para o último conjunto de treino, enquanto que a segunda opção, com 12 neurónios, tem uma trajetória sempre descendente.

Na tabela que se segue podemos observar os valores numéricos que nos ajudam a perceber melhor as curvas apresentadas no gráfico 25.

Tabela 14 - Média do EQM do preditor da irradiância para Julho

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,02762	0,03186	<b>0,01726</b>	0,0184
<b>8</b>	0,02482	0,03936	0,03122	0,03726
<b>10</b>	0,0584	0,04938	0,04068	0,04974
<b>12</b>	0,0557	0,04842	0,03924	0,038
<b>15</b>	0,03854	0,04454	0,0311	0,05538
<b>Média</b>	0,04102	0,04271	<b>0,03190</b>	0,03976

Tendo por base a tabela, e analisando os valores resultantes da média do erro quadrático médio para cada conjunto de treino, conseguimos descortinar qual o que obteve melhor performance para o preditor em questão, ou seja, o que apresentar valor de média mais reduzido. Quanto ao número de neurónios a usar o melhor resultado (0,01726) foi obtido com 5 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 5 neurónios na camada oculta e um conjunto de treino de 25 dias.

Desta forma, utilizando os parâmetros anteriormente definidos, quer para o preditor da temperatura quer para o da irradiância, realizamos a sua previsão, de modo a ser possível efetuar a previsão da produção fotovoltaica.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de julho podem ser observados no gráfico 26.




Gráfico 26 - Produção fotovoltaica por hora real e prevista para Julho

Analisando a gráfico anterior, que retrata a comparação entre os valores reais e previstos médios por hora para a produção fotovoltaica para um dia do mês de julho de 2018, observamos que os valores de produção estão compreendidos entre os 0W e 3000W, sendo que durante todo o intervalo de medição, os valores previstos ultrapassam sempre os valores da produção real. É possível constatar que tanto a produção real como a prevista apresentam um comportamento comum, ou seja, a produção é mínima na primeira hora de medição crescendo até às 14h, onde a produção é máxima para ambas as variáveis. A partir dessa hora até ao final das horas de medição observamos um decréscimo nos valores obtidos. É ainda possível verificar que na primeira metade do gráfico a diferença entre os valores reais e previstos é inferior à diferença apresentada na segunda metade do horizonte de medição.



#### 4.1.8 Agosto

No gráfico seguinte observamos a variação do erro quadrático médio do predictor da temperatura para o mês de agosto, tendo em consideração os diferentes conjuntos adotados e o atraso previamente considerado.




Gráfico 27 - EQM do predictor de temperatura para Agosto

Analisando o gráfico 27, é possível observar que os resultados obtidos para o erro quadrático médio se encontram entre os 0,005 e os 0,035, verificamos a existência de 2 padrões comportamentais comuns. O primeiro é notório nas curvas relativas aos modelos com 10 e 12 neurónios, na medida que do conjunto de 15 dias até ao conjunto de 25 dias a sua trajetória é descendente, e ascendente dos 25 para os 30 dias. O segundo padrão é observável nas curvas dos modelos de 5 e 8 neurónios na camada oculta da rede, uma vez que apresentam um comportamento muito semelhante ao longo de todos os conjuntos de treino. Relativamente a este mês, o modelo que apresenta para quase todos os conjuntos o menor valor para o erro quadrático médio é o que compreende 10 neurónios na camada oculta, como é possível constatar no gráfico acima, ou seja, é o que apresenta melhor performance.

Na seguinte tabela, são analisados em pormenor os resultados previamente obtidos de modo a decidir a combinação de parâmetros a utilizar neste predictor.

Tabela 15 - Média do EQM do preditor da temperatura para Agosto

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,0149	0,0219	0,01196	0,01428
<b>8</b>	0,01522	0,02068	0,0093	0,01026
<b>10</b>	0,0156	0,01032	<b>0,0087</b>	0,01696
<b>12</b>	0,01942	0,01406	0,01324	0,02416
<b>15</b>	0,03298	0,02468	0,02986	0,0125
<b>Média</b>	0,01962	0,01833	0,01461	0,01563

Por observação da tabela, constatamos que o número mais baixo para a média do erro quadrático médio relativo a cada conjunto de treino, é obtido no de 25 dias (0,01461), sendo este o melhor conjunto a utilizar no desenvolvimento do modelo deste preditor. Quanto ao número de neurónios a usar o melhor resultado (0,0087) foi obtido com 10 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 10 neurónios na camada oculta e um conjunto de treino de 25 dias.

O procedimento seguido em relação à temperatura foi também utilizado para a irradiância. No gráfico seguinte observamos os valores do erro quadrático médio obtidos.




Gráfico 28 - EQM do preditor de irradiância para Agosto

Visualizando o gráfico 28, constatamos que os valores do erro quadrático médio obtidos para o preditor da irradiância para o mês de agosto encontram-se compreendidos entre os 0,005 e os 0,045, sendo possível concluir que os modelos não apresentam um comportamento semelhante, uma vez que a oscilação entre valores é um pouco diferente para os vários conjuntos de treino. É possível ainda observar que o modelo relativo a 8 neurónios presentes na camada oculta da rede é que apresenta o valor mais reduzido para o erro quadrático médio nos conjuntos de 15 e 20 dias, e o segundo valor mais baixo nos conjuntos de 25 e 30 dias, ou seja, é o modelo que apresenta melhor performance. Curiosamente, focando-nos no conjunto de treino de 15 dias, os modelos que apresentam o pior e segundo pior resultado, exibem o menor valor para nos conjuntos de 25 e 30 dias, respetivamente.

Com recurso à tabela abaixo apresentada, é possível analisar os valores referentes ao erro quadrático médio bem como a média obtida para cada conjunto de treino, no preditor da irradiância.

Tabela 16 - Média do EQM do preditor da irradiância para Agosto

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,03552	0,02626	0,01358	0,0093544
<b>8</b>	0,01728	0,0147241	<b>0,01146</b>	0,01312
<b>10</b>	0,03156	0,03158	0,0248	0,02602
<b>12</b>	0,02958	0,02736	0,01556	0,0268
<b>15</b>	0,04146	0,04026	0,0104032	0,02146
<b>Média</b>	0,03108	0,02804	<b>0,01516</b>	0,01935

Observando os valores presentes na tabela 16, verificamos que o resultado mais baixo obtido para a média do erro quadrático médio de cada conjunto de treino, se verificou no conjunto de 25 dias (0,01516). Quanto ao número de neurónios a usar o melhor resultado (0,01146) foi obtido com 8 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 8 neurónios na camada oculta e um conjunto de treino de 25 dias.

Em seguida, adotando as medidas tomadas para os preditores da temperatura e irradiância, estimamos os valores para um mesmo dia de agosto de 2018 com o objetivo de os utilizar como variáveis de entrada da modelo que prevê a produção fotovoltaica para este mês.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de agosto podem ser observados no gráfico 29.




Gráfico 29 - Produção fotovoltaica por hora real e prevista para Agosto

O gráfico apresenta a comparação entre os valores estimados e reais médio por hora da produção fotovoltaica para um dia de agosto de 2018. Analisando o mesmo verificamos que a produção está compreendida entre os 0W e os 4500W para o dia analisado. Novamente, e como esperado, a produção real segue um padrão comum, ou seja, uma produção mínima às primeiras e últimas horas de medição e valores mais elevados de produção ao centro. Relativamente aos valores previstos, é possível verificar que entre as 6 e as 13h os valores reais são superiores aos previstos, invertendo-se a situação às 14h e 15h e a partir das 18h. Nas últimas horas de medição, (das 19h às 21h), é onde estão as maiores diferenças, indicando uma performance menos boa do modelo durante essas horas.

#### 4.1.9 Setembro

No gráfico 30, observamos a variação dos valores do erro quadrático médio para o preditor da temperatura no mês de setembro, tendo em conta o atraso previamente considerado e os diferentes conjuntos de treino estudados.




Gráfico 30 - EQM do preditor de temperatura para Setembro

Por constatação do gráfico, é possível visualizar que os valores referentes ao erro quadrático médio neste preditor variam entre 0 e 0,06, e que à exceção do modelo com 15 neurónios presentes na camada oculta da rede, todos os restantes apresentam um comportamento em torno de valores mais próximos (oscilando entre 0,01 e 0,03). Dentro dos 4 modelos com comportamento semelhante é possível observar 2 padrões distintos. Os modelos com 8 e 10 neurónios contêm uma trajetória descendente dos 15 aos 25 dias e uma trajetória ascendente dos 25 para os 30 dias, e os que apresentam 5 e 12 neurónios na camada oculta da rede possuem trajetória ascendente dos 15 para os 20 dias e dos 25 para os 30 dias, enquanto que dos 20 para os 25 é descendente, como acontece com todos os modelos estudados neste mês.

Na seguinte tabela são apresentados em maior detalhe os resultados obtidos, de modo a decidir a melhor combinação de parâmetros a utilizar.

Tabela 17 - Média do EQM do preditor da temperatura para Setembro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,01228	0,02632	<b>0,0095</b>	0,02004
<b>8</b>	0,02192	0,01874	0,0136	0,0209
<b>10</b>	0,01618	0,01342	0,011876	0,02812
<b>12</b>	0,02	0,02722	0,0178	0,02838
<b>15</b>	0,02512	0,05078	0,0068	0,02992
<b>Média</b>	0,01910	0,02729	<b>0,01192</b>	0,02547

Por observação dos valores presentes na tabela, mais propriamente da média do erro quadrático médio de cada conjunto de treino, conseguimos avaliar qual a melhor combinação entre número de neurónios e conjunto de treino a utilizar. Quanto ao número de neurónios a usar o melhor resultado (0,0095) foi obtido com 5 neurónios.

Assim podemos concluir que, o conjunto com menor valor de média é o de 25 dias (0,01192), e foram utilizados 5 neurónios na camada oculta da rede, uma vez que o modelo com o menor valor para este conjunto de treino apresenta grande variabilidade de resultados, tendo-se optado pelo modelo com o segundo melhor valor no conjunto considerado.

Novamente, tal como procedido para a temperatura, também para a irradiância foi efetuado o mesmo estudo em relação ao conjunto de treino e número de neurónios a utilizar. Os valores do erro quadrático médio para as várias combinações encontram-se no seguinte gráfico.




Gráfico 31 - EQM do preditor de irradiância para Setembro

No gráfico 31, observamos que os valores referentes ao erro quadrático médio alternam entre 0,01 e 0,05, não sendo observável um padrão de comportamento comum a nenhum dos modelos em estudo, nem sendo possível descortinar apenas com recurso ao gráfico apresentado qual o modelo que apresenta melhor performance. Observamos também que, os 2 modelos que apresentam os valores mais elevados relativamente ao erro quadrático médio para o conjunto de treino de 15 dias, verificam os valores mais reduzidos no conjunto de treino de 30 dias.

Assim, recorrendo à tabela seguinte como suporte, é possível perceber melhor a combinação de parâmetros a utilizar neste preditor.

Tabela 18 - Média do EQM do preditor da irradiância para Setembro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
5	0,03636	0,03102	0,02542	0,0316
8	0,03848	0,04138	0,03032	0,03392
10	0,0495	0,03174	0,0297	0,0219
12	0,04998	0,03224	0,03344	<b>0,01618</b>
15	0,02628	0,03072	0,02996	0,03372
<b>Média</b>	0,04012	0,03342	0,029768	<b>0,027464</b>



Visualizando os dados presentes na tabela anterior, tendo em conta o menor resultado obtido para a média do erro quadrático médio nos conjuntos de treino considerados, verificamos que a melhor combinação a utilizar consiste num conjunto de 30 dias. Quanto ao número de neurónios a usar o melhor resultado (0,01618) foi obtido com 12 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 12 neurónios na camada oculta e um conjunto de treino de 30 dias.

Assim, tendo por base as decisões tomadas relativamente aos preditores da temperatura e irradiância, estimamos os valores para um mesmo dia de setembro de 2018, uma vez que estes valores serão utilizados para prever a produção fotovoltaica para este mês

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de setembro podem ser observados no gráfico seguinte.




Gráfico 32 - Produção fotovoltaica por hora real e prevista para Setembro

Analisando o gráfico 32, que apresenta a comparação entre os valores reais e previstos médios por hora relativamente à produção fotovoltaica num dia do mês de setembro de 2018, constatamos que estes se encontram compreendidos entre os 0W e os 5000W. Como expectável, o padrão seguido pelos valores reais apresenta valores mínimos nas primeiras e últimas horas de medição, e valores máximos de produção no centro do gráfico. Um outro dado é que os valores são

crescentes até às 14h, hora a partir da qual começam a decrescer até final das horas de medição. Relativamente aos valores previstos pelo modelo desenvolvido, não apresentam um padrão comum de crescimento, apresentando as maiores diferenças face à produção real às primeiras horas da manhã, na última hora de medição. Podemos ainda observar que a previsão prevista apenas é superior à real no início e no fim do dia.

É também notório que este modelo não apresenta uma boa performance quando comparado com outros meses, uma vez que no período das 14h às 18h a produção real é bastante superior à produção prevista.

#### 4.1.10 Outubro

No gráfico 33, conseguimos visualizar a variação do erro quadrático médio relativamente ao predictor da temperatura no mês de outubro, com a finalidade de encontrar a melhor combinação entre o número de neurónios e o conjunto de treino a utilizar.




Gráfico 33 - EQM do predictor de temperatura para Outubro

Analisando o gráfico anterior, é notório que os valores do erro quadrático médio variam entre 0,01 e 0,05, e que todos os modelos se desenvolvem em torno de valores próximos nos conjuntos de treino de 25 e 30 dias (oscilando entre 0,01 e 0,03). É também possível constatar que todos os modelos, à exceção do que contém 15 neurónios, do conjunto de 15 dias para o conjunto de 20 dias apresentam uma trajetória descendente, e que todos, menos o modelo que compreende na camada oculta 12 neurónios, do conjunto dos 20 para os 25 dias exibem novamente uma trajetória descendente, indicando desta forma uma melhoria de performance. Considerando o modelo que apresenta menor valor do erro quadrático médio nos conjuntos de 25 e 30 dias, o de 5 neurónios, verificamos que para o conjunto de 15 dias é o que apresenta o segundo resultado mais elevado.

Com recurso à tabela seguinte é possível aferir qual o conjunto de treino a utilizar assim como o número de neurónios presente na camada oculta da rede.

Tabela 19 - Média do EQM do preditor da temperatura para Outubro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,0356	0,02738	<b>0,0148</b>	0,01522
<b>8</b>	0,02634	0,02314	0,01928	0,02278
<b>10</b>	0,03416	0,02792	0,01766	0,0180235
<b>12</b>	0,02242	0,0153	0,01928	0,01882
<b>15</b>	0,04134	0,04968	0,01878	0,0191
<b>Média</b>	0,03197	0,02868	<b>0,01796</b>	0,01879

Avaliando os resultados obtidos e registados na tabela anterior, podemos verificar que o melhor conjunto de treino a utilizar é o de 25 dias, uma vez que é onde se obtem uma média mais baixa para o valor do erro quadrático médio (0,01796). Quanto ao número de neurónios a usar o melhor resultado (0,0148) foi obtido com 5 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 5 neurónios na camada oculta e um conjunto de treino de 25 dias.

Como efetuado para o preditor da temperatura, também para o preditor da irradiância seguimos o mesmo procedimento, e os resultados obtidos para o erro quadrático médio encontram-se dispostos no gráfico 34.




Gráfico 34 - EQM do predictor de irradiância para Outubro

Pela análise do gráfico anterior, observamos que os valores obtidos para o erro quadrático médio estão compreendidos entre 0 e 0,07, sendo possível distinguir os modelos que apresentam melhor performance, uma vez que exibem resultados mais baixos comparativamente aos restantes. Estes são os que compreendem 5 e 8 neurónios na camada oculta da rede (oscilando entre 0 e 0,04), como é possível perceber pelo gráfico, já que, para todos os conjuntos o menor valor do erro quadrático médio é alcançado por um destes modelos. É também possível verificar que, qualquer que seja o modelo considerado, o valor mais baixo obtido aconteceu nos 25 dias, e consequentemente desde os 15 até aos 25 a trajetória das curvas é descendente indicando uma melhoria de performance, e dos 25 para os 30 dias as trajetórias são todas ascendentes, piorando a performance entre estes 2 conjuntos.

Na tabela seguinte encontram-se os dados indicados no gráfico 34.

Tabela 20 - Média do EQM do preditor da irradiância para Outubro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,03254	0,01226	0,0115	0,02078
<b>8</b>	0,02664	0,0185	<b>0,00966</b>	0,03588
<b>10</b>	0,05768	0,03306	0,02206	0,03208
<b>12</b>	0,06448	0,0466	0,02364	0,0383
<b>15</b>	0,05266	0,06366	0,02184	0,06794
<b>Média</b>	0,0468	0,034816	<b>0,01774</b>	0,038996

Analisando a tabela 20, é claramente perceptível qual o conjunto de treino mais aconselhável a utilizar, pois o conjunto relativo a 25 dias exibe o melhor resultado para a média do erro quadrático médio (0,01774), comparativamente aos restantes. Quanto ao número de neurónios a usar o melhor resultado (0,00966) foi obtido com 8 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 8 neurónios na camada oculta e um conjunto de treino de 25 dias.

Desta forma, efetuamos a previsão da temperatura e da irradiância para um mesmo dia do mês de outubro, de modo a estimar a produção de energia fotovoltaica para o mês em questão.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de outubro podem ser observados no gráfico 35.




Gráfico 35 - Produção fotovoltaica por hora real e prevista para Outubro

O gráfico mostra a comparação entre os valores previstos e reais médio por hora para a produção fotovoltaica, para um dia de outubro de 2018. Pela análise efetuada, verificamos que os valores se encontram entre os 0W e os 6500W, sendo que quer a produção real como a produção prevista seguem um padrão comum, ou seja, durante as primeira se últimas horas de medição têm um valor praticamente inexistente, enquanto que no centro do gráfico apresentam valores bem mais elevados. Também é possível verificar um aumento dos valores desde as 6h até às 13h, intervalo onde se verifica uma maior produção prevista, e uma diminuição desde as 14h até às 21h. Outra constatação é que até às 13h os valores da produção prevista são superiores à produção real, invertendo-se esta tendência a partir das 15h.

#### 4.1.11 Novembro

Para encontrar a melhor combinação entre o número de neurónios presentes na camada oculta e o conjunto de treino a utilizar, registamos os valores obtidos relativamente ao erro quadrático médio. No gráfico 36, é apresentada a variação do erro quadrático médio para o preditor da temperatura no mês de novembro.




Gráfico 36 - EQM do preditor de temperatura para Novembro

Analisando o gráfico, é possível observar que os valores obtidos para o erro quadrático médio no preditor da temperatura para o mês de novembro variam entre 0,03 e 0,05, e que os modelos apresentam um comportamento semelhante para os diferentes conjuntos de treino, uma vez que a oscilação de valores é reduzida. É também possível constatar que o modelo referente a 12 neurónios presentes na camada oculta é o que apresenta melhor performance para todos os conjuntos de treino considerados no estudo, como é possível observar no gráfico 36, uma vez que a sua curva se encontra abaixo de todas as restantes.

Com recurso à tabela seguinte, é possível tomar uma decisão melhor fundamentada relativamente aos parâmetros a utilizar no desenvolvimento do preditor da temperatura.



Tabela 21 - Média do EQM do preditor da temperatura para Novembro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,04144	0,04354	0,03484	0,0484
<b>8</b>	0,04278	0,03824	0,03788	0,04458
<b>10</b>	0,03654	0,03956	0,03474	0,04814
<b>12</b>	0,03118	0,0373	<b>0,0307</b>	0,04196
<b>15</b>	0,04918	0,04068	0,03254	0,04502
<b>Média</b>	0,04022	0,03986	<b>0,03414</b>	0,04562

Analisando a tabela 21, é possível constatar que o resultado mais baixo obtido para a média do erro quadrático médio para cada conjunto foi verificado com 25 dias (0,03414). Quanto ao número de neurónios a usar o melhor resultado (0,0307) foi obtido com 12 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 12 neurónios na camada oculta e um conjunto de treino de 25 dias.

Tal como efetuado para o preditor da temperatura, também para o preditor da irradiância é necessário verificar qual a combinação entre número de neurónios e conjunto de treino a utilizar.

No gráfico 37, observamos a variação do erro quadrático médio para o mês de novembro para o preditor da irradiância.




Gráfico 37 - EQM do preditor de irradiância para Novembro

Observando o gráfico anterior, é possível constatar que os valores do erro quadrático médio do preditor em questão se encontram entre 0,04 e 0,1, e que apesar de não existir uma grande oscilação ou discrepância entre os resultados, nenhum dos modelos apresenta um comportamento idêntico. O único ponto de comparação encontrado reside no facto de todos os modelos, neste mês e para este preditor, com exceção do que contém 5 neurónios na camada oculta da rede, apresentarem uma trajetória descendente dos 15 aos 25 dias e uma trajetória descendente dos 25 para os 30 dias o que indica uma melhoria de performance no primeiro intervalo considerado, contrariamente ao sucedido para o segundo. Focando-nos no modelo que contém 12 neurónios na camada oculta, verificamos que apesar de apresentar o pior resultado para o erro quadrático médio no conjunto de 15 dias, no conjunto relativo a 30 dias é o modelo que apresenta melhor performance.

A tabela seguinte ajuda a uma melhor compreensão dos resultados, de modo a escolher a melhor combinação de variáveis a utilizar.

Tabela 22 - Média do EQM do preditor da irradiância para Novembro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,0526	0,06604	0,06032	0,0573
<b>8</b>	0,07142	0,05424	0,04958	0,06156
<b>10</b>	0,07896	0,04512	<b>0,04128</b>	0,06652
<b>12</b>	0,09864	0,0786	0,05256	0,05556
<b>15</b>	0,0776	0,0685	0,0528	0,08176
<b>Média</b>	0,07584	0,06250	0,05131	0,06454

Pela análise efetuada aos resultados obtidos e apresentados na tabela 22, concluímos que o conjunto de treino que apresenta o menor valor para a média do erro quadrático médio é o de 25 dias (0,05131). Quanto ao número de neurónios a usar o melhor resultado (0,04128) foi obtido com 10 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 10 neurónios na camada oculta e um conjunto de treino de 25 dias.

Em seguida, tanto para a irradiância como para a temperatura e utilizando os preditores anteriores, foi efetuada a previsão dos valores para um dia do mês de novembro, a fim de ser possível estimar a produção fotovoltaica.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de novembro podem ser observados no gráfico 38.




Gráfico 38 - Produção fotovoltaica por hora real e prevista para Novembro

Por análise ao gráfico 38, que representa a comparação entre os valores reais e previstos médios por hora da produção fotovoltaica para um dia do mês de novembro de 2018, é possível constatar que os resultados se encontram entre os 0W e os 9500W para os valores estimados, enquanto que os valores reais se encontram entre os 0W e os 7000W, notando uma diferença máxima de aproximadamente 2700W. Verificamos também que o comportamento das duas variáveis, como expectável, é similar, consistindo num aumento dos valores obtidos desde as 6h até às 13h para a produção prevista e até às 14h para a real, e numa diminuição até às 20h de ambas. A produção prevista apresenta valores superiores até às 16h, invertendo-se a partir daí esta situação, à exceção das 21h onde a produção prevista volta a ser superior. As maiores diferenças entre a produção real e prevista são entre as 12h e as 14h.

#### 4.1.12 Dezembro

No seguinte gráfico conseguimos observar, para o mês de dezembro, a variação do erro quadrático médio para as diversas combinações utilizadas, tendo em conta o atraso da rede considerado e escolhido anteriormente.




Gráfico 39 - EQM do preditor de temperatura para Dezembro

Por observação do gráfico anterior constatamos que, os valores obtidos para o erro quadrático médio oscilam entre 0,02 e 0,055, que o modelo que tem 10 neurónios na camada oculta possui pior performance, quando comparado com os restantes, visto que para os conjuntos de 20 e 25 dias apresenta o pior valor do erro quadrático médio. É também possível verificar que os modelos com 5 e 15 neurónios presentes na camada oculta dispõem de um padrão muito semelhante, já que ambos apresentam uma trajetória descendente dos 15 aos 25 dias e uma ascendente dos 25 para os 30 dias, onde a diferença entre os resultados obtidos para os diversos conjuntos não ultrapassa as 5 milésimas. Porém o conjunto com mais neurónios apresenta melhor performance. Por outro lado, o modelo que apresenta a melhor performance é o que contém 12 neurónios, visto que tanto para o conjunto de 15 como para o de 30 dias revela o melhor resultado para o erro quadrático médio.

Na tabela seguinte é possível observar em maior detalhe os resultados obtidos, assim como a média do erro quadrático médio para cada conjunto de treino.

Tabela 23 - Média do EQM do preditor da temperatura para Dezembro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,03988	0,0327	0,0269	0,03662
<b>8</b>	0,03148	0,02662	0,0349	0,0414
<b>10</b>	0,0374	0,0517	0,04624	0,02832
<b>12</b>	0,02396	0,0291	0,02954	<b>0,02138</b>
<b>15</b>	0,04056	0,02868	0,02348	0,03134
<b>Média</b>	0,03466	0,03376	0,03221	<b>0,03181</b>

Averiguando os resultados presentes na tabela, constatamos que o conjunto que apresenta o menos valor para a média do erro quadrático médio é o de 30 dias (0,03181). Quanto ao número de neurónios a usar o melhor resultado (0,02138) foi obtido com 12 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da temperatura para este mês apresenta 12 neurónios na camada oculta e um conjunto de treino de 30 dias.

Assim como para a temperatura, também para a irradiância é necessário efetuar o estudo dos parâmetros a utilizar no seu preditor. No gráfico 40 encontram-se os valores obtidos para o erro quadrático médio, tendo em conta o atraso da rede considerado.




Gráfico 40 - EQM do preditor de irradiância para Dezembro

Por observação dos resultados obtidos, é possível verificar que os valores relativos ao erro quadrático médio das previsões efetuadas se encontram entre 0,03 e 0,07, que todos os modelos se desenvolvem em torno de valores próximos, e que o modelo com melhor performance é o que apresenta na camada oculta da rede desenvolvida 8 neurónios, visto que para todos os conjuntos de treino deste preditor, para o mês de dezembro, este é que exibe menor valor relativamente ao erro quadrático médio obtido na previsão, como conseguimos constatar no gráfico X. Apesar de não ser facilmente observável, os modelos com 5 e 15 neurónios na camada oculta, têm um comportamento semelhante, visto que tanto para o conjunto de 15 dias como para o de 30 dias, apresentam os 2 piores resultados para o erro quadrático médio.

A tabela apresentada em seguida compreende os valores obtidos para o preditor da irradiância, servindo de apoio a uma melhor compreensão dos valores acima representados.

Tabela 24 - Média do EQM do preditor da irradiância para Dezembro

Neurónios na camada oculta	Conjunto de treino			
	15 dias	20 dias	25 dias	30 dias
<b>5</b>	0,06732	0,05156	0,05636	0,0594
<b>8</b>	0,0461	0,043	<b>0,03528</b>	0,05246
<b>10</b>	0,0476	0,05094	0,04498	0,05404
<b>12</b>	0,06226	0,05582	0,04362	0,05438
<b>15</b>	0,06984	0,05694	0,04208	0,05888
<b>Média</b>	0,05862	0,05165	<b>0,04446</b>	0,05583

Observando os valores presentes na tabela é notório que o conjunto de treino de 25 dias apresenta um valor mais baixo para a média do erro quadrático médio de cada conjunto de treino, quando comparado com os restantes (0,04446). Quanto ao número de neurónios a usar o melhor resultado (0,03528) foi obtido com 8 neurónios.

Deste modo podemos concluir que a combinação mais favorável relativamente ao preditor da irradiância para este mês apresenta 8 neurónios na camada oculta e um conjunto de treino de 25 dias.

Tomando por base as decisões tomadas anteriormente, tanto para o preditor da temperatura como para o da irradiância, efetuamos a previsão dos valores para um mesmo dia do mês de fevereiro, a fim de estimar a produção de energia fotovoltaica para o mês em questão.

Os valores da comparação da produção fotovoltaica real e prevista relativamente ao mês de dezembro podem ser observados no gráfico 41.






Gráfico 41 - Produção fotovoltaica por hora real e prevista para Dezembro

Analisando o gráfico anterior, que representa a comparação entre os valores estimados e reais médios por hora para a produção fotovoltaica para um dia de dezembro de 2018, é possível observar que a produção se situa entre os 0W e os 5000W, sendo estes valores sempre superiores na produção real, ao longo de todas as horas de medição. Conseguimos também constatar que, quer a produção estimada quer a produção real apresentam um padrão comum, ou seja, às primeiras e últimas horas de medição a produção é quase inexistente ou mesmo nula, sendo máxima às 13h para a real e às 14h para a prevista. Por observação da diferença entre as 2 variáveis comparadas neste gráfico, observamos que esta é máxima às 12h e que durante as restantes horas de medição se verifica uma grande discrepância, indicando que o modelo referente a este mês apresenta uma performance inferior à obtida para os restantes meses.

## 4.2 Apresentação Anual

Na tabela que se segue apresentamos a compilação dos dados tendo em conta a combinação mais favorável entre o conjunto de treino a considerar e o número de neurónios contidos na camada oculta do modelo desenvolvido, relativamente ao preditor da temperatura e de irradiância.

Tabela 25 - Combinação anual do conjunto de treino e número de neurónios para os preditores da temperatura e irradiância

Meses do ano	Temperatura		Irradiância	
	Conjunto de Treino	Número de neurónios	Conjunto de Treino	Número de neurónios
<b>Janeiro</b>	25 dias	8	25 dias	5
<b>Fevereiro</b>	20 dias	12	20 dias	15
<b>Março</b>	25 dias	12	30 dias	10
<b>Abril</b>	15 dias	8	25 dias	5
<b>Maio</b>	25 dias	12	25 dias	5
<b>Junho</b>	25 dias	8	25 dias	12
<b>Julho</b>	30 dias	10	25 dias	5
<b>Agosto</b>	25 dias	10	25 dias	5
<b>Setembro</b>	25 dias	5	30 dias	12
<b>Outubro</b>	25 dias	5	25 dias	8
<b>Novembro</b>	25 dias	12	25 dias	10
<b>Dezembro</b>	30 dias	12	25 dias	8

Por observação da tabela acima, podemos concluir que o melhor resultado obtido para o preditor da temperatura na maioria dos meses corresponde a um conjunto de treino de 25 dias à exceção dos meses de fevereiro, abril, julho e dezembro. Relativamente ao número de neurónios presentes na camada oculta, verificamos uma grande variabilidade de resultados, tendo obtido uma ocorrência de 12 neurónios para cinco combinações, 8 neurónios para três combinações, e 5 e 10 neurónios para duas combinações cada. De salientar ainda que nenhuma combinação envolveu 15 neurónios na camada oculta.

Quanto ao preditor da irradiância, a maioria dos meses corresponde a um conjunto de treino de 25 dias, excetuando os meses de fevereiro, março e setembro. Relativamente ao número de neurónios presentes na camada oculta também aqui verificamos uma grande variabilidade de resultados, tendo obtido uma ocorrência de 5 neurónios para cinco combinações, 8 neurónios para duas combinações, 10 e 12 neurónios para duas combinações cada, e 15 neurónios para apenas uma combinação.

No gráfico seguinte apresentamos a comparação entre a produção fotovoltaica total real e prevista para cada um dos meses do ano estudado.




Gráfico 42 - comparação entre a produção fotovoltaica total real e prevista anual

Por observação do gráfico anterior, podemos verificar que os valores totais por mês da produção fotovoltaica se situam abaixo de 260.000 W. Os dados obtidos demonstram que nos meses de primavera/verão quer a produção real quer a produção prevista apresentam valores mais baixos. Os valores mais elevados na produção fotovoltaica verificaram-se nos três primeiros meses do ano e nos três últimos (meses de inverno), à exceção do mês de dezembro. É também nestes meses que verificamos maiores diferenças entre a produção real e a produção prevista, à exceção do mês de fevereiro.

Relativamente ao mês de dezembro observamos um comportamento atípico, quando comparado com os restantes meses de inverno, uma vez que os valores quer da produção real quer da produção prevista são muito baixos.

A razão explicativa para que a produção fotovoltaica seja menor entre os meses de abril e agosto, pensamos que poderá ter a ver com o facto dos módulos fotovoltaicos estarem incorporados na fachada do edifício, que se encontra voltada a sul de modo a receber radiação durante as horas de sol diárias, o que faz com que o ângulo de inclinação do módulo relativamente ao solo seja de  $90^\circ$ . Nos meses de inverno como a posição relativa do sol é mais baixa comparativamente aos meses de verão, nesta instalação, o ângulo de incidência dos raios solares é menor aumentando a produção efetuada nesses meses.

## 5 CONCLUSÕES E TRABALHO FUTURO

O objetivo do trabalho consistiu em prever a energia fotovoltaica produzida num edifício inovador (nZEB), tendo por base os dados referentes à temperatura ambiente e à radiação proveniente do sol (irradiância).

Para responder ao objetivo proposto, foram utilizados os dados de temperatura, irradiância e produção fotovoltaica compreendidos entre 2015 e 2017, sendo estes dados usados como variáveis de treino dos modelos, enquanto que os relativos a 2018 foram aproveitados para efetuar a comparação para os diferentes modelos entre os valores previstos e os reais de produção fotovoltaica. Seguindo uma metodologia para todos os meses, foram criados 12 modelos distintos de previsão fotovoltaica, que permitiram escolher a melhor combinação entre o conjunto de treino e o número de neurónios presentes na camada oculta a utilizar nos preditores da temperatura e irradiância.

Pelo agrupamento dos melhores resultados para cada mês, obtivemos o número de ocorrências mais comuns para cada preditor, o que permitiu retirar as seguintes conclusões:

1 – O melhor resultado obtido para o preditor da temperatura na maioria dos meses corresponde a um conjunto de treino de 25 dias, correspondente a oito ocorrências, e com 12 neurónios na camada oculta, sendo registado em cinco meses diferentes;

2 - O melhor resultado obtido para o preditor da irradiância, na maioria dos meses corresponde a um conjunto de treino de 25 dias, correspondente a nove ocorrências, e com 5 neurónios na camada oculta, sendo registado em cinco meses diferentes;

3 – Considerando os dois preditores, temperatura e irradiância, apenas num deles foi identificada como melhor resultado uma combinação que contém 15 neurónios na camada oculta da rede. Pensamos que esta constatação se deve à complexidade acrescida que o aumento deste parâmetro cria no cálculo dos pesos efetuado pela rede neuronal, influenciando desta forma a performance dos resultados atingidos pela rede em questão.

Quanto à produção fotovoltaica para os diferentes meses do ano, retiramos as seguintes conclusões:

1 – Os meses que apresentam valores mais elevados de produção quer real quer prevista, são os meses do início do ano (janeiro, fevereiro, março) e o mês de novembro, enquanto que, os que apresentam valores mais baixos são os meses de primavera/verão/outono (de abril a outubro).

2 – Nos meses de primavera/verão/outono (entre abril e outubro) a produção fotovoltaica total, quer real quer prevista, apresenta uma tendência em crescendo e valores bastante próximos entre ambas o que indicia uma melhor performance para os modelos nos meses em questão. Este facto pode ser explicado pelo melhor comportamento dos dados utilizados, uma vez que nos meses de primavera/verão/outono, os dias são maiores e existem mais dias de sol, implicando que os dados presentes no conjunto de treino não apresentem grandes oscilações.

3 - Quando comparamos a produção total, real e prevista, para cada um dos meses do ano, verificamos que, as maiores diferenças foram obtidas nos meses de início e final do ano (janeiro, março, novembro e dezembro), o que indica que os modelos referentes a estes meses apresentam uma pior performance, podendo esta ser explicada pela presença de mais dias sem sol e dias mais curtos, o que perturba o comportamento dos modelos e consequentemente a previsão efetuada.

Como recomendações a utilizar para trabalhos futuros, sugere-se um melhor pré-processamento dos dados, com a utilização de modelos ARMA (modelo auto-regressivo de médias móveis), sendo estes aplicados de modo a obter uma correlação entre as variáveis de entrada e as variáveis de saída, podendo apresentar uma melhoria na performance obtida.

Uma outra opção para melhoria da performance obtida passa pelo uso de mais variáveis de entrada, como por exemplo de variáveis meteorológicas, em vez de considerar apenas a temperatura e a irradiância medidas no local de produção.

## Bibliografia

- Anwar, Khalid, e Sandip Deshmukh. «Use of Artificial Neural Networks for Prediction of Solar Energy Potential in Southern States of India». Em *2018 2nd International Conference on Green Energy and Applications (ICGEA)*, 63–68. Singapore: IEEE, 2018. <https://doi.org/10.1109/ICGEA.2018.8356321>.
- Asdrubali, Francesco, Luca Evangelisti, e Claudia Guattari. «Evaluation of the Energy and Environmental Payback Time for a NZEB Building», sem data, 6.
- Carlisle, N., Elling, J., & Penney, T. A Renewable Energy Community: Key Elements. NREL/TP-540-42774, (2008)
- Chaturvedi, D K. «Solar Power Forecasting: A Review». *International Journal of Computer Applications* 145 (sem data): 23.
- D’Agostino, Delia, e Livio Mazzarella. «What Is a Nearly Zero Energy Building? Overview, Implementation and Comparison of Definitions». *Journal of Building Engineering* 21 (Janeiro de 2019): 200–212. <https://doi.org/10.1016/j.jobbe.2018.10.019>.
- Gebben, Florian, Sebastian Bader, e Bengt Oelmann. «Configuring Artificial Neural Networks for the Prediction of Available Energy in Solar-Powered Sensor Nodes». Em *2015 IEEE SENSORS*, 1–4. Busan: IEEE, 2015. <https://doi.org/10.1109/ICSENS.2015.7370253>.
- Larson, David P., Lukas Nonnenmacher, e Carlos F.M. Coimbra. «Day-Ahead Forecasting of Solar Power Output from Photovoltaic Plants in the American Southwest». *Renewable Energy* 91 (Junho de 2016): 11–20. <https://doi.org/10.1016/j.renene.2016.01.039>.
- Leva, S., A. Dolara, F. Grimaccia, M. Mussetta, e E. Ogliari. «Analysis and Validation of 24 Hours Ahead Neural Network Forecasting of Photovoltaic Output Power». *Mathematics and Computers in Simulation* 131 (Janeiro de 2017): 88–100. <https://doi.org/10.1016/j.matcom.2015.05.010>.
- Maia, Rian Sardinha. «ENERGIA SOLAR: O DESENVOLVIMENTO DE UM NOVO MERCADO», sem data, 87.
- Meenal, R., e A. Immanuel Selvakumar. «Review on Artificial Neural Network Based Solar Radiation Prediction». Em *2017 2nd International Conference on Communication and Electronics Systems (ICCES)*, 302–5. Coimbatore: IEEE, 2017. <https://doi.org/10.1109/CESYS.2017.8321285>.
- Nespoli, Alfredo, Emanuele Ogliari, Alberto Dolara, Francesco Grimaccia, Sonia Leva, e Marco Mussetta. «Validation of ANN Training Approaches for Day-Ahead Photovoltaic Forecasts». Em *2018 International Joint Conference on Neural Networks (IJCNN)*, 1–6. Rio de Janeiro: IEEE, 2018. <https://doi.org/10.1109/IJCNN.2018.8489451>.
- Park, J.-W., G.K. Venayagamoorthy, e R.G. Harley. «MLP/RBF Neural-Networks-Based Online Global Model Identification of Synchronous Generator». *IEEE Transactions on Industrial Electronics* 52, n. 6 (Dezembro de 2005): 1685–95. <https://doi.org/10.1109/TIE.2005.858703>.
- Serra, Filipe Carreira. «Implementação de Fontes de Energia Renovável em Meio Urbano», sem data, 131.
- Yaici, Wahiba, Evgueniy Entchev, Michela Longo, Morris Brenna, e Federica Foiadelli. «Artificial Neural Network Modelling for Performance Prediction of Solar Energy System». Em *2015 International Conference on Renewable Energy Research and Applications (ICRERA)*, 1147–51. Palermo, Italy: IEEE, 2015. <https://doi.org/10.1109/ICRERA.2015.7418589>.
- Zeng, Jianwu, e Wei Qiao. «Short-Term Solar Power Prediction Using an RBF Neural Network». Em *2011 IEEE Power and Energy Society General Meeting*, 1–8. Detroit, MI, USA: IEEE, 2011. <https://doi.org/10.1109/PES.2011.6039204>.

- Agoua, Xwegnon Ghislain, Robin Girard, e George Kariniotakis. «Short-Term Spatio-Temporal Forecasting of Photovoltaic Power Production». *IEEE Transactions on Sustainable Energy* 9, n. 2 (Abril de 2018): 538–46. <https://doi.org/10.1109/TSTE.2017.2747765>.
- Fente, Dires Negash, e Dheeraj Kumar Singh. «Weather Forecasting Using Artificial Neural Network», 2018, 5.
- Zhou, Hangxia, Yujin Zhang, Lingfan Yang, Qian Liu, Ke Yan, e Yang Du. «Short-Term Photovoltaic Power Forecasting Based on Long Short Term Memory Neural Network and Attention Mechanism». *IEEE Access* 7 (2019): 78063–74. <https://doi.org/10.1109/ACCESS.2019.2923006>.
- S. Hochreiter, J. Schmidhuber, Long short-term memory, *Neural computation*, 9(8):1735-1780,1997.
- Jones LE, “Strategies and Decision Support Systems for Integrating Variable Energy Resources in Control Centers for Reliable Grid Operations-Global Best Practices, Examples of Excellence and Lessons Learned”.
- Schmidt, Thomas, Martina Calais, Eric Roy, Ashton Burton, Detlev Heinemann, Thilo Kilper, e Craig Carter. «Short-Term Solar Forecasting Based on Sky Images to Enable Higher PV Generation in Remote Electricity Networks». Editado por David Goodfield. *Renewable Energy and Environmental Sustainability* 2 (2017): 23. <https://doi.org/10.1051/rees/2017028>.
- Cros, S., O. Liandrat, N. Sebastien, e N. Schmutz. «Extracting Cloud Motion Vectors from Satellite Images for Solar Power Forecasting». Em *2014 IEEE Geoscience and Remote Sensing Symposium*, 4123–26. Quebec City, QC: IEEE, 2014. <https://doi.org/10.1109/IGARSS.2014.6947394>.
- Perez R, Kivalov S, Schlemmer J, Hemker K Jr., Renne D, Hoff TE, “Validation of short and medium term operational solar radiation forecasts in the US”, *Solar Energy*, in press, 2010a.
- Safieddine, S., A. Boynard, P.-F. Coheur, D. Hurtmans, G. Pfister, B. Quennehen, J. L. Thomas, et al. «Summertime Tropospheric Ozone Assessment over the Mediterranean Region Using the Thermal Infrared IASI/MetOp Sounder and the WRF-Chem Model». *Atmospheric Chemistry and Physics* 14, n. 18 (23 de Setembro de 2014): 10119–31. <https://doi.org/10.5194/acp-14-10119-2014>.
- Traunmüller W, Steinmaurer G. “Solar irradiance forecasting, benchmarking of different techniques and applications of energy meteorology”. *Proceedings of the EuroSun 2010 conference*. September 28 – October 1, 2010, Graz, Austria.
- Bacher P, Madsen H, Nielsen HA. “Online short-term solar power forecasting”, *Solar Energy*, 2009;83(10):1772-83.
- Madsen, Henrik, Pierre Pinson, George Kariniotakis, Henrik Aa. Nielsen, e Torben S. Nielsen. «Standardizing the Performance Evaluation of Short-Term Wind Power Prediction Models». *Wind Engineering* 29, n. 6 (Dezembro de 2005): 475–89. <https://doi.org/10.1260/030952405776234599>.
- Lorenz E, Hurka J, Heinemann D, Beyer HG. “Irradiance forecasting for the power prediction of grid connected photovoltaic systems”. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 2009; 2 (1), pp. 2-10. <https://doi.org/10.1109/JSTARS.2009.2020300>.
- Lorenz E, Remund J, Müller SC, Traunmüller W, Steinmaurer G, Pozo D, Ruiz-Arias JA, Lara Fanego V, Ramirez L, Romeo MG, Kurz C, Pomares LM, Guerrero CG, 2009b. “Benchmarking of Different Approaches to Forecast Solar Irradiance”. *Proceedings of the 24th European Photovoltaic Solar Energy Conference 2009*; Hamburg, Germany: pp. 4199-4208. <https://doi.org/10.4229/24thEUPVSEC20095BV.2.50>.
- Müller SC and Remund J. “Advances in radiation forecast based on regional weather models MM5 and WRF”. *25th European Photovoltaic Solar Energy Conference*. Valencia, Spain, 6-10 September, 2010.
- H. Nazaripouya, B. Wang, Y. Wang, P. Chu, H. R. Pota, e R. Gadh, «Univariate time series prediction of solar power using a hybrid wavelet-ARMA-NARX prediction method», em *2016 IEEE/PES Transmission and Distribution Conference and Exposition (T&D)*, Dallas, TX, USA, 2016, pp. 1–5, doi: 10.1109/TDC.2016.7519959.



- L. B. Mohammed, M. A. Hamdan, E. A. Abdelhafez, e W. Shaheen, «Hourly Solar Radiation Prediction Based on Nonlinear Autoregressive Exogenous (Narx) Neural Network», vol. 7, n. 1, p. 8, 2013.
- A. El Hendouzi e A. Bourouhou, «Forecasting of PV power application to PV power penetration in a microgrid», em 2016 International Conference on Electrical and Information Technologies (ICEIT), Tangiers, Morocco, 2016, pp. 468–473, doi: 10.1109/EITech.2016.7519644.
- E. Sarwat, «Nonlinear Autoregression Neural Network for Meteorological Parameters Forecasting to Evaluate the Behavior of Radioactive Material Release from Nuclear Power Plants», IJCA, vol. 1, n. 8, 2018, doi: 10.26808/rs.ca.i8v1.07.